

إصدار مكتبة الشروق



الذكاء الاصطناعي

Artifitial-Intelligence

من الأساسيات وحتى النهايات

نسخة عربية

الفهرس

الفصل الأول: مدخل إلى الذكاء الصناعي

- 1- الذكاء 1
- 2- الذكاء الصناعي 1
- 3- مجالات الذكاء الصناعي 2
- 4- ما هو الحاسوب الذكي 3
- 5- مقارنات عامة 4
- 1- ما الفرق بين الذكاء الطبيعي والذكاء الصناعي؟ 4
- 2- ما الفرق بين المعالجة الحاسوبية والمعالجة البشرية للمعطيات؟ 4
- 3- ما الفرق بين الذكاء الصناعي والبرمجة التقليدية؟ 5
- 6- هندسة المعرفة 5
- 1- نطاق المعرفة 6
- 2- ما هي هندسة المعرفة؟ 6
- 3- طرق هندسة المعرفة 6
- 7- فلسفة تمثيل المعرفة 7
- 1- الدور الأول: إيجاد البديل عن المعرفة بهدف المحاكمة عليها. 8
- 2- الدور الثاني: إبداع مفاهيم عامة في المعرفة Ontologies 8
- 3- الدور الثالث: اعتماد نظرية تجزئية للمحاكمة الذكية. 9
- 4- الدور الرابع: إيجاد وسط ليعبر الناس عن معرفتهم. 11
- 5- الدور الخامس: إيجاد وسيط ليعبر الناس عن معرفتهم 11
- 8- مراجع البحث 11

الفصل الثاني: حل المشاكل باستخدام الفرضيات وحساب الإسناديات

- 1- استخدام المنطق في المحاكمة 12
- 2- حساب الفرضيات 13
- 1- اللغة 13
- 2- قواعد الاستدلال 14
- 3- الدلالة 15
- 4- الحل 18
- 5- الحل بالنقض 19
- 6- عبارات هورن 20
- 3- حساب الإسناديات Predicates 21
- 1- اللغة 21
- 2- قواعد الاستدلال 22

- 22..... التوحيد 3-
- 25..... الحل 4-
- 26..... استخراج الجواب 5-
- 27..... تمارين 4-
- 28..... مراجع البحث 5-

الفصل الثالث: طرق أخرى لتمثيل المعرفة والنظم الخبيرة

- 29..... نظم قواعد الإنتاج 1-
- 29..... السلسلة الأمامية 1-
- 30..... السلسلة الخلفية 2-
- 30..... مقارنة بين السلسلة الأمامية والسلسلة الخلفية 3-
- 31..... مشاكل قواعد الإنتاج وحلول 4-
- 32..... شبكات الدلالة 2-
- 38..... ترابط المفاهيم 3-
- 41..... الأطر Frames 4-
- 46..... السيناريو 5-
- 49..... تمارين 6-
- 50..... مراجع البحث 7-

الفصل الرابع: إيجاد الحلول الموضعية وخوارزميات البحث

- 51..... فضاء الحالات 1-
- 55..... البحث في فضاء الحالات 2-
- 59..... بيان المسائل الجزئية 3-
- 60..... الشجرة and-or 4-
- 61..... البحث التجريبي 5-
- 63..... مراجع البحث 6-

الفصل الخامس: المعرفة والتفكير المتلبسين

- 64..... مراجعة الاحتمالات 1-
- 67..... قاعدة بايز والمحكمة باستخدامها 2-
- 70..... الشك 3-
- 71..... عوامل اليقين 4-
- 72..... المنطق العائم 5-
- 74..... مراجع البحث 6-

75..... الفصل السادس: التعلم

- 75 1- مقدمة
- 76 2- التعلم الاستقرائي: الشبكات العصبونية
- 79 3- التعلم الاستنتاجي عبر الأمثلة
- 84 4- الألعاب
- 86 5- مراجع البحث

78 الفصل السابع: التواصل والإدراك والفعل

- 87 1- مقدمة
- 87 2- حلقة التحسس/ التخطيط/الفعل
- 88 3- تعلم دوال تجريبية
- 91 4- الجوائز عوضاً عن الأهداف
- 92 5- التخطيط في الألعاب ذات اللاعبين
- 93 6- إجراء min-Max
- 98 7- مراجع البحث

99 الفصل الثامن: استشراف المستقبل: الخوارزميات المتطورة

- 99 1- مقدمة
- 99 2- الخوارزميات الجينية
- 102 3- البرمجة الجينية
- 103 4- نظم ذكية هجينة
- 104 5- مراجع البحث

:

.1

—

:



:(

)



:



.2

learning

reasoning

perception

acting

communicating

)

(

:

.

:

:

"

.. ()

"

(Haugeland 1985)

(Charniak & McDermott 1985)

...

:

(Barr & Feigenbaum (Jackson chapter 2))

.3

:



.(

....(

)

.4

Data

Information

.false true

. "fuzzy logic"

- Switches

Turing

Turing

(B)

(A)

(C) Interrogator

.()

."A Y B X" "B Y A X"

Y X

B A

()

X :C

C A . A A X

Turing

B A

(Turing)

)

Joseph Weizenbaum

ELISA

(

Mauldin

JULIA

.5

تستخدم رموزاً لتمثيل مفاهيم المسألة ومعالجتها بهدف اتخاذ قرارات	تستخدم أرقاماً، ومحارف
ثمة تمثيل مجرد للمعرفة ¹ ، وجداول ² يجري تعلمها لحل المسائل	تستخدم الذاكرة والملفات لتخزين المعلومات والبرامج.
تستخدم برمجة منطقية وغيرها	تستخدم خوارزميات
تستخدم الكسبيات (Heuristics) والاستدلال ومواءمة الأشكال لاتخاذ قرارات أعقد ناجمة عن الخبرة	تنتج قرارات بسيطة...

)

c) (Jess clips C++ lisp prolog
C# Pascal (...).

:

الذكاء الصناعي	البرمجة التقليدية
يقوم بمعالجة رموز	تقوم بمعالجة حسابية
قد لا يكون الدخل والخرج معروفين تماماً في النظم الذكية	الدخل والخرج معروفان تماماً بالخوارزميات
البحث عن الحل تجريبي	ثمة خوارزميات للبحث
التركيز على المعرفة	التركيز على المعطيات والمعلومات
فصل التحكم عن المعطيات، إضافة معطيات جديدة مستقلة عن إضافة أدوات محاكاة وتحكم جديدة	المعطيات مدمجة مع أدوات التحكم، وأي تغيير يتطلب إعادة ترجمة البرامج قبل التنفيذ
سهولة التحديث نسبياً	صعوبة التحديث للسبب السابق

Knowledge Engineering

.6

1
...
2
:




:

:

•

•

•

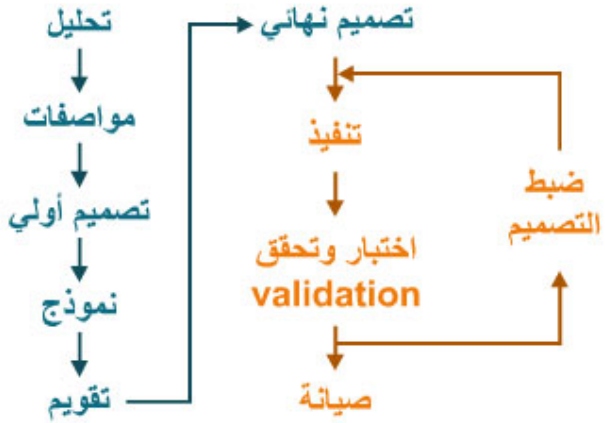


مكونات نظام خبير (نظم قواعد المعرفة)

knowledge base
inference engine

Working Memory

دورة حياة هندسة المعرفة



.7

:

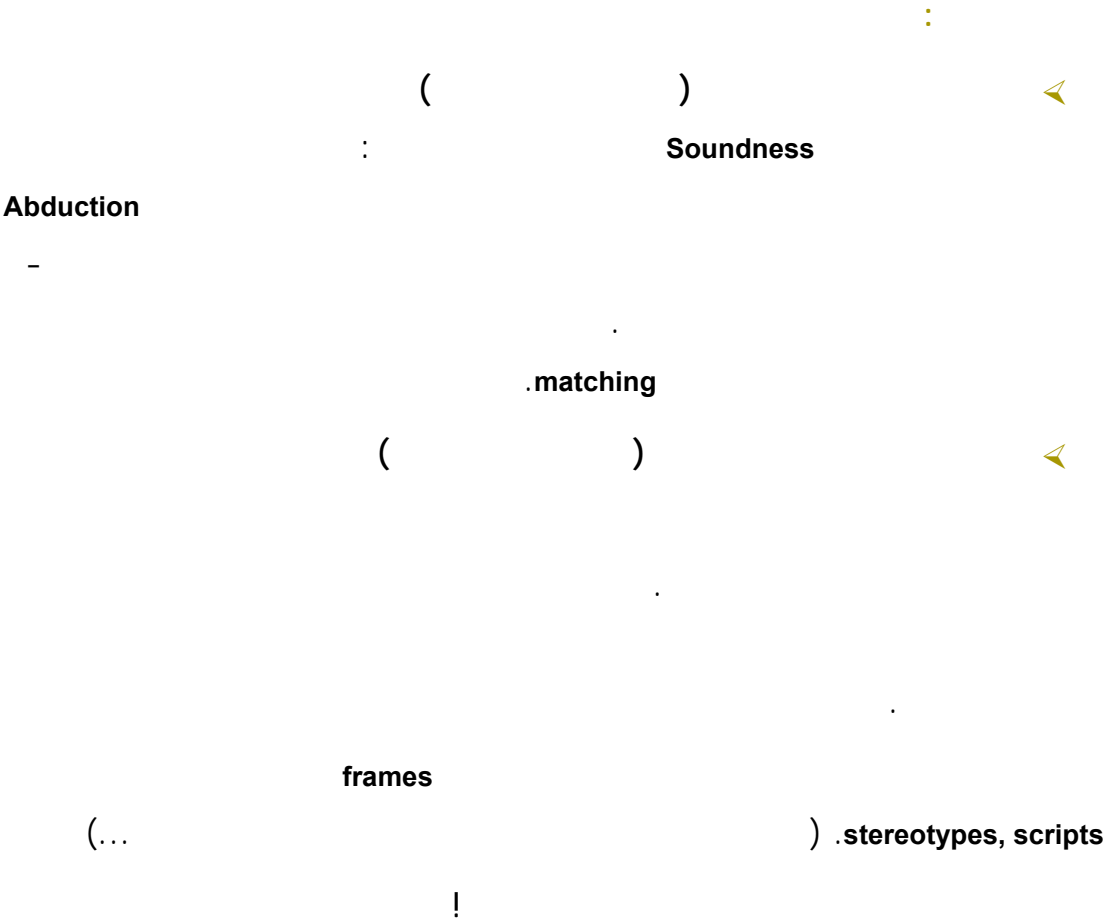
.1

.		
.() Ontologies	.2
()	.3
	.(
	:	.4
	.	
	:	.5
	.	
	.	
	.	
	:	
	.	
	:	
	"	"
	:	
	"	"
)	(...)
	(...	
	.	
	.	
	:	
	(..)
	...	
	:	
	:)
	(...	

[illegible]

Mathematical	Psychology	Biology	Statistics	Economics
Logic				
Aristotle				
Descartes				
Boole	James		Laplace	Bentham, Pareto
Frege		Bernoulli	Friedman	
Peano				
	Hebb	Lashley	Bayes	
Goedel	Bruner	Rosenblatt		
Post	Miller	Ashby	Tversky	Von Neumann
Church	Newell	Lettvin	Kahneman	Simon
Turing	Simon	McCulloch, Pitts		Raiffa
Davis		Heubel, Weisel		
Putnam				
Robinson				
LOGIC	SOAR	CONNECTIONISM	Causal networks	Rational agents
PROLOG	Knowledge-based systems	A-life		
	Frames			

Views of Intelligent Reasoning and Their Intellectual Origins



:

.1

) present
future .(
"reasoning" (.)
"planning"

"symptoms" "causes"
"expert systems"

() :

(TRUE,
: FALSE)

(BAT_OK) x_1
(LIFTABLE) x_2
(MOVES) x_3
()
) MOVES () BAT_OK
LIFTABLE .LIFTABLE (

1 LIFTABLE BAT_OK
0 MOVES 1 MOVES

BAT_OK .0 () LIFTABLE BAT_OK
 .0 LIFTABLE 1

language

inference

propositional calculus

BAT_OK ^ :

LIFTABLE \supset MOVES

. " " \supset " " ^

:

.()

:

propositional calculus

first order predicate

.(FOPC) calculus

.2

:

(False True) F T :atoms

.(P, Q, R,..., P1, P2, ON_A_B,... :

. " " " " " " " " "

$\neg \supset \wedge \vee$:connectives

: (wffs) well-formed formulas

.P3 R P :



:

$\omega_2 \quad \omega_1$



$\omega_2 \quad \omega_1$

$(\omega_2 \quad \omega_1) \quad \omega_1 \vee \omega_2$

$(\omega_2 \quad \omega_1) \quad \omega_1 \wedge \omega_2$

$(\quad) \quad \omega_1 \supset \omega_2$

$(\omega_1) \quad \neg \omega_1$

:

$(P \wedge Q) \supset \neg P$

$P \supset \neg P$

$P \vee P \supset P$

$(P \supset Q) \supset (\neg Q \supset \neg P)$

$\neg \neg P$

$\omega_1 \supset \omega_2 \quad \omega_1$

.Literal \neg



. consequent ω_2

antecedent

$P \supset \neg \neg :$



$(P \wedge Q) \supset \neg R$

$\neg R \quad Q \quad P$

$(P \wedge Q)$

$(P \wedge Q) \supset \neg R \quad R$

rules of

.inference

:

$(\beta \quad \alpha) \quad \alpha \quad \gamma$

:

$(\omega_1 \supset \omega_2 \quad \omega_1) \quad \omega_2$






.(modus ponens

$(\wedge) \quad \omega_2 \quad \omega_1 \quad \omega_1 \wedge \omega_2$



$(\wedge) \quad \omega_1 \wedge \omega_2 \quad \omega_2 \wedge \omega_1$



(\wedge) $\omega_1 \wedge \omega_2$ ω_1 
 (\vee) ω_2 ω_1 $\omega_1 \vee \omega_2$ 
 (\neg) $\neg(\neg\omega_1)$ ω_1 
 ω_n (deduction) Proof $\{\omega_1, \omega_2, \dots, \omega_n\}$
 Δ ω_1 Δ
 (\quad)
 Δ theorem ω_n Δ ω_n
 $\Delta \models \omega_n$ $:\Delta$ ω_n
 $:$
 $:\Delta$

$\Delta = \{P, R, P \supset Q\}$


:

$Q \wedge R$

$\{P, P \supset Q, Q, R, Q \wedge R\}$

Δ

wff



semantics

()

propositions

"The Battery is charged" "

"

¹BAT_OK

.interpretation

.denotation

P

α

.False True

¹ لسنا مضطرين إلى استخدام سلسلة محرفية سهلة التذكر، إذ يمكن الاستعاضة عنها بسلسلة محرفية أخرى.

ω_1	ω_2	$\omega_1 \wedge \omega_2$	$\omega_1 \vee \omega_2$	$\neg \omega_1$	$\omega_1 \supset \omega_2$
True	True	True	True	False	True
True	False	False	True	False	False
False	True	False	True	True	True
False	False	False	False	True	True

16

True ²valid

:

$$P \supset P (\neg P \vee P)$$

T

$$\neg (P \wedge \neg P)$$

$$Q \vee T$$

$$[(P \supset Q) \supset P] \supset P$$

$$P \supset (Q \supset P)$$

equivalent

:

:DeMorgan

$$\neg (\omega_1 \vee \omega_2) \equiv \neg \omega_1 \wedge \neg \omega_2$$

$$\neg (\omega_1 \wedge \omega_2) \equiv \neg \omega_1 \vee \neg \omega_2$$

:Contrapositive

$$(\omega_1 \supset \omega_2) \equiv (\neg \omega_2 \supset \neg \omega_1)$$

:

$$\omega_2 \quad \omega_1$$

$$(\omega_1 \supset \omega_2) \wedge (\omega_2 \supset \omega_1)$$

$$.(\omega_1 \supset \omega_2) \wedge (\omega_2 \supset \omega_1) \quad \omega_1 \equiv \omega_2$$

True

$$\omega \quad \Delta \quad \omega \quad \omega$$

$$\Delta$$

True

$$\Delta$$

$$: \quad .\Delta \models \omega$$

$$\models$$

$$.\Delta$$

$$\{P\} \models P$$

$$\{P, P \supset Q\} \models Q$$

$$F \models \omega$$

$$\omega$$

$$P \wedge Q \models P$$

$$(\quad)$$

$$\Delta$$

$$\omega$$

$$\Delta$$

$$\omega$$

$$\Delta \quad \omega \quad \Delta \models \omega$$

.

.

$$\Delta \quad \omega \quad \Delta \quad \omega$$

$$) \Delta \quad \omega$$

.

(

)

(

Resolution

$$\{\neg\lambda\} \cup \Sigma_2 \quad \{\lambda\} \cup \Sigma_1$$

$$\lambda$$

$$\Sigma_2 \quad \Sigma_1$$

$$\lambda$$

(

$$\Sigma_2 \quad \Sigma_1$$

$$\Sigma_1 \cup \Sigma_2$$

.

:

$$.R \vee Q \quad \neg P \vee Q \quad R \vee P$$



$$.P \supset Q \quad \neg R \supset P$$

$$\neg R \supset Q$$

chaining

$$.R \vee Q$$

$$R \supset P$$

$$:P \quad \neg R \vee P \quad R$$



.

$$Q$$

$$:Q \vee R \vee S \vee W$$

$$P$$

$$\neg P \vee Q \vee W$$

$$P \vee Q \vee R \vee S$$



.(

)

$$\lambda$$

(

$$\neg\lambda$$

(

$$\lambda$$



$$\neg\lambda \quad \lambda$$

:

$$\neg\lambda \quad \lambda$$

$$\mathbf{F}$$

$$\neg\lambda$$

.

.

)

.(

$\neg (P \supset Q) \vee (R \supset P) :$

\vee .1

$\neg (\neg P \vee Q) \vee (\neg R \vee P)$

$(\neg P \vee Q \quad P \supset Q) \neg$.2

:

$(P \wedge \neg Q) \vee (\neg R \vee P)$

.3

$\neg (P \wedge Q) = (\neg P) \vee (\neg Q)$

$\neg (P \vee Q) = (\neg P) \wedge (\neg Q)$

:

$(P \vee \neg R \vee P) \wedge (\neg Q \vee \neg R \vee P)$

:

$(P \vee \neg R) \wedge (\neg Q \vee \neg R \vee P)$

$:(\quad)$

$\{ (P \vee \neg R), (\neg Q \vee \neg R \vee P) \}$

:

Δ

wff

.()

Δ



w



. Γ



Γ



:

BAT_OK (1)

¬MOVES (2)

BAT_OK \wedge LIFTABLE \supset MOVES (3)


• •

$$\neg \text{BAT_OK} \vee \neg \text{LIFTABLE} \vee \text{MOVES} \quad (4)$$

—LIFTABLE

•

•

LIFTABLE (5)

$\neg \text{BAT_OK} \vee \text{MOVES}$

(5) (4) (6)

¬BAT_OK

(6) (2) (7)

Nil

(7) (1) (8)

•

:



:Refinement


$$(\quad)$$


• •

.Q	P	Fact
----	---	------



.(Rule)



.P ∧ Q ⊃ R



wff

Goal

.P^Q⊃

predicates

.3

B

.C

ON_B_C

B

ON_B_C ON_A_B

P124

()

.Q23

()

ON_B_C ⊃ ¬CLEAR_C

C B) C

CLEAR_C

.(C

y x On (x,y)⊃¬Clear (y)

:

.object constants



Aa, 13B, John, :

.EiffelTower

:

function constants




distanceBetween(Damascus, Homs)
times (5, 4)

relation constants
 Son(Radwan, :
 .Anas)

times (4, x):

() [] $\exists \forall \supset \neg \wedge \vee$

:



- Block (A) ●
- Block (B) ●
- Block (C) ●
- Floor (F1) ●
- On (B,A) , On (A,C).. ●
- Clear (B) ●

:

	A	A
	B	B
	C	C
	Floor	F1
On = {<B,A>, <A,C>, <C,Floor>}		On
Clear = {}		Clear

:)

:

$(\forall x)P(x, f(x), B)$:Universal Instantiation

.x A x P(A, f(A), B)

$(\forall x)Q(A, g(A), x)$:Existential Generalization

. $(\exists y)(\forall x)Q(y, g(y), x)$

:

إذا لم تكن صيغة محققة مهما يكن متحولها فهذا يعني أنه يوجد مثال لا تتحقق من أجله الصيغة. $\neg(\forall \xi) \omega(\xi) \equiv (\exists \xi) \neg \omega(\xi)$
 إذا لم يوجد مثال تتحقق الصيغة من أجله فهذا يعني أنها غير محققة مهما يكن متحولها. $\neg(\exists \xi) \omega(\xi) \equiv (\forall \xi) \neg \omega(\xi)$
 يمكن تغيير المتحول الأصم للمكمي الشمولي \forall دون أن تتأثر دلالة الصيغة. $(\forall \xi) \omega(\xi) \equiv (\forall \eta) \omega(\eta)$

()

$$\neg \lambda(\tau) \quad \left(\begin{array}{c} \xi \\ \tau \end{array} \right) \quad \lambda(\xi) \quad \left(\begin{array}{c} \xi \\ \tau \end{array} \right)$$

Resolvent

$$f(y) \quad x \quad \neg P(x,A) \vee R(x,C) \vee S(A,B) \quad P(f(y),A) \vee Q(B,C) \\ \neg P(f(y),A) \vee R(f(y),C) \vee S(A,B)$$

$$R(f \quad P(f(y),A) \quad (y),C) \vee S(A,B) \vee Q(B,C)$$

unification

$$P[x,f(y),B] \quad \text{substitution instance}$$

$$P[z,f(w),B] \quad P[x,f(A),B] \quad P[g(z),f(A),B] \quad P[C,f(A),B]$$

alphabetic variant

$$P[x,f(y),B]$$

ground instance

$$\tau_i/\xi_i \quad s=\{\tau_1/\xi_1, \tau_2/\xi_2, \dots, \tau_n/\xi_n\}$$

$$\tau_i \quad \xi_i$$

:

التعبير			
P[x,f(y),B]	P[x,f(A),B]	P[g(z),f(A),B]	P[C,f(A),B]
P[z,f(w),B]	P[x,f(A),B]	P[g(z),f(A),B]	P[C,f(A),B]
s1 ={z/x,w/y}	s2 ={A/y}	s3 ={g(z)/x,A/y}	s4 ={C/x,A/y}

$$s1 \quad s2 \quad s1s2 \quad s2 \quad s1 \\ s2 \quad s1 \quad s1 \quad s2 \\ (\omega s1)s2=\omega(s1s2) \quad \omega \quad s1s2 \quad \omega \\ (s1s2)s3=s1(s2s3)$$

$$: \quad s2=\{A/y\} \quad s1=\{f(y)/x\} \quad P(x,y) \quad \omega$$

$$\omega(s_1s_2)=[P(x,y)]\{f(A)/x,A/y\}=P(f(A),A) \quad (\omega s_1)s_2=[P(f(y),y)]\{A/y\}=P(f(A),A)$$

$$.s_1s_2=s_2s_1 \quad :$$

$$s_2 \quad s_1 \quad \omega$$

$$\omega(s_1s_2)=P(f(A),A)$$

$$\omega(s_2s_1)=[P(x,y)]\{A/y,f(y)/x\}=P(f(y),A)$$

$$\{\omega_i\}$$

$$s$$

$$s$$

$$\text{unifiable}$$

$$\{\omega_i\}$$

$$.\{\omega_i\}s$$

$$\{\omega_i\}$$

$$\text{unifier}$$

$$s$$

$$\omega_1s = \omega_2s = \omega_3s = \dots$$

$$s=\{A/x,B/y\}$$

$$.\text{singleton}$$

$$s=\{A/x,B/y\}$$

$$.\{P[A,f(B),B]\}$$

$$\{P[x,f(y),B],P[x,f(B),B]\}$$

$$\{P[x,f(y),B],P[x,f(B),B]\}$$

$$\text{most } (\quad)$$

$$\{\omega_i\} \quad g$$

$$. \quad A \quad x \quad (\quad)$$

$$s'$$

$$\{\omega_i\}s$$

$$\{\omega_i\} \quad s$$

$$\text{general unifier (mgu)}$$

$$)$$

$$.\{\omega_i\}s=\{\omega_i\}gs'$$

$$.($$

$$.(\quad)$$

$$\text{UNIFY}$$

$$\neg P(x,f(A,y))$$

$$\text{list-structured}$$

$$\neg P$$

$$(\neg Px(f \ A \ y))$$

$$(f \ A \ x)$$

$$.\text{disagreement set}$$

$$\text{UNIFY}$$

$$)$$

$$W$$

$$W$$

$$W$$

$$($$

$$\{(\neg Px(f \ A \ y)) , (\neg Px(f \ z \ B))\}$$

$$.W$$

.{A,z}

.A/z

UNIFY

.{P[A,f(B),B]}

{P[A,f(y),B],P[x,f(B),B]}:

s={A/x,B/y}

:

UNIFY (Γ)

- 1 $k \leftarrow 0$; $\Gamma_k \leftarrow \Gamma$; $\sigma_k \leftarrow \varepsilon$
- 2 if Γ_k is singleton, exit with σ_k , the mgu of Γ , otherwise continue
- 3 $D_k \leftarrow$ the disagreement set of Γ_k
- 4 If there exists elements v_k, t_k in D_k such that v_k is a variable that does not occur in t_k continue. Otherwise exit with failure; Γ is not unifiable
- 5 $\sigma_{k+1} \leftarrow \sigma_k\{t_k/v_k\}$; $\Gamma_{k+1} \leftarrow \Gamma_k\{t_k/v_k\}$
- 6 $k \leftarrow k+1$
- 7 Go to 2

حيث Γ مجموعة قوائم مهيكلة من التعبيرات

الخطوة الابتدائية. (ε هو التعويض الفارغ)

إذا كانت Γ_k أحادية، أخرج من الإجراء مرجعاً σ_k وهي الموحد الأعم لـ Γ ، وإلا فتابع

نضع في D_k مجموعة عدم التوافق لـ Γ_k

إذا وجد عنصران v_k و t_k في المجموعة D_k حيث v_k متغير لا يظهر في t_k تابع، وإلا فأخرج وأعلن الإخفاق، وتكون Γ غير قابلة للتوحيد

لاحظ أن $\Gamma_{k+1} = \Gamma_k\sigma_{k+1}$

أضف واحداً إلى k

اذهب إلى الخطوة 2

wff

:

($\neg x \vee y \quad x \Rightarrow y$

\vee

)

(

)

(

)

.($\forall x$)[$\neg P(x) \vee (\exists y)Q(y)$]

($\forall x$)[$\neg P(x) \vee (\exists x)Q(x)$]

($\forall x$)

($\forall x$)($\exists y$) Height(x,y) :

(

)

.Height(x,h(x))

(

) Prenex Form

\wedge



27


: 28

$\forall (x,y)\{\text{package}(x) \wedge \text{package}(y) \wedge \text{inroom}(x,27) \wedge \text{inroom}(y,28)\} \supset \text{smaller}(x,y)$

$\neg P(x) \neg \forall P(y) \neg \forall I(x,27) \neg \forall$

$I(y,28) \vee S(x,y)$

P = package, I = inroom, S = smaller :



Ans (u)

.(A

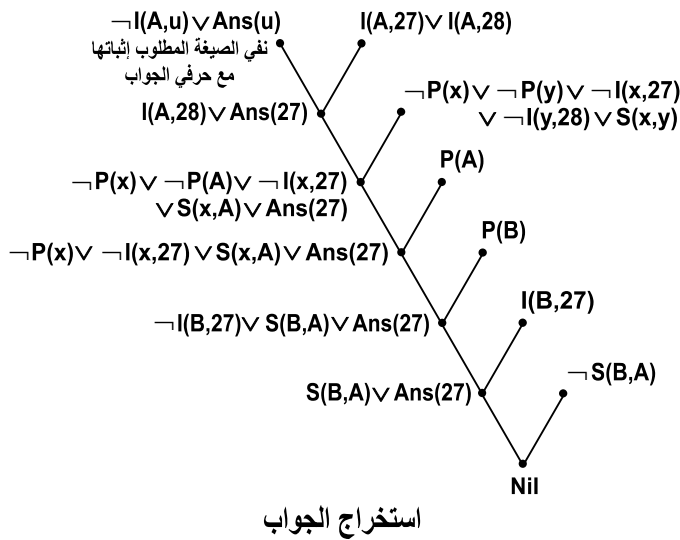
)

u

u

$(\exists u) I(A,u) :$

.A



.A 27

.4

.1

P(A,y,z) P(x,B,B) .1

P(x,x) P(g(f(v)),g(u)) .2

P(y,y) (x,f(x)) .3

P(z,x,z) P(y,y,B) .4

x=3+3 2+3=x .5

.P(f(y,f(y,A)),A)

P(f(x,x),A)

.2

: clause form

.3

((∃x)[P(x)] ∨ (∃x)[Q(x)]) ⊃ (∃x)[P(x) ∨ Q(x)] .1

(∀x)[P(x) ⊃ (∀y)[(∀z)[Q(x,y)] ⊃ ¬(∀z)[R(y,x)]]] .2

(∀x)[P(x)] ⊃ (∃x)[(∀z)[Q(x,z)] ∨ (∀z)[R(x,y,z)]] .3

(∀x)[P(x) ⊃ Q(x,y)] ⊃ ((∃y)[P(y)] ∧ (∃z)[Q(y,z)]) .4

.4

"Tony, Mike, and John belong to the Alpine Club. Every member of the Alpine Club is either a skier or a mountain climber or both. No mountain climber likes rain, and all skiers like snow. Mike dislikes whatever Tony likes and likes whatever Tony dislikes. Tony likes rain and snow."

.Alpine

John Mike Tony"

.Tony

Tony

Mike

".

Tony

"Who is a member of the Alpine Club who is a mountain climber but not a skier?"

"

"

:Oscar Clyde Sam

.5

1. Sam is pink.
2. Clyde is gray and likes Oscar.
3. Oscar is either pink or gray (but not both) and likes Sam.

			Sam	.1
		Oscar	Clyde	.2
Sam	()	Oscar	.3

$(\exists x,y)[\text{Gray}(x) \wedge \text{Pink}(y) \wedge \text{Likes}(x,y)]$

.5

2004

"

"



➤ Giarratano & Riley "Expert Systems: Principles and Programming", 3d Edition, 1998

.1

()



()



Prolog

Clips

()

()

Forward chainig

Backward Chaining

(Q P) .Fact



.(Rule)



(P^Q^R) .



wff

) .Goal

(P^Q^

elephant(x)^mammel(x) :

x

x

الاستخدام	التحكم، التخطيط	التشخيص
مقادير	المعطيات	الهدف
المحاكمة	من الأسفل إلى الأعلى، إيجاد النتائج التي تدعمها المعطيات	من الأعلى إلى الأسفل، إيجاد حقائق تدعم فرضيات
يشبه خوارزميات البحث	عرضاً أولاً	عمقاً أولاً



.2

)
:
!



CYC

CYC .() Thing

:things

“ X is a P, all P’s are Q’s, All Q’s are R’s”

"R Q Q P P X"

.frames

Snoopy :

Laser_Printer(Snoopy)

$(\forall x) [\text{Laser_Printer}(x) \supset \text{Printer}(x)]$

$(\forall x) [\text{Printer}(x) \supset \text{Office_Machine}(x)]$

categories Office_Machine Printer Laser_Printer

Office_Machine(Snoopy) $(\forall x) [\text{Laser_Printer}(x) \supset \text{Office_Machine}(x)]$

$(\forall x)[\text{Office_Machine}(x) \supset [\text{Energy_Source}(x) = \text{Wall_Outlet}]]$

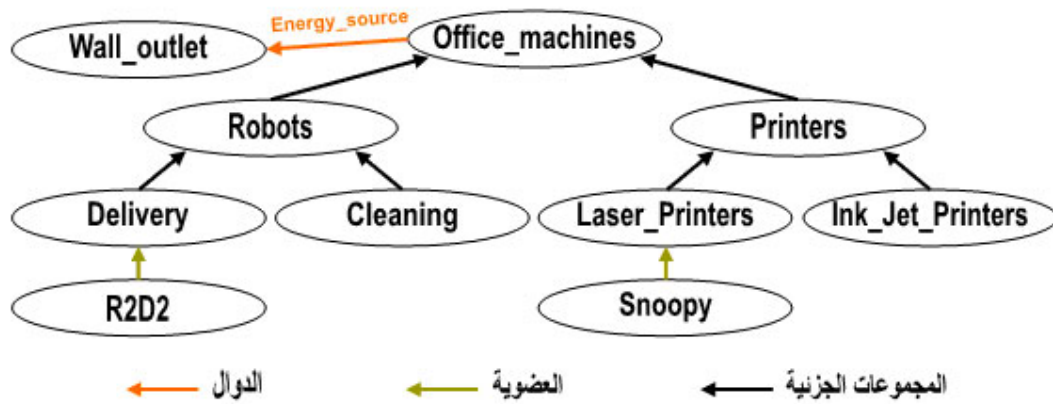
$(\forall x)[\text{Laser_Printer}(x) \supset [\text{Energy_Source}(x) = \text{Wall_Outlet}]]$

.Semantic network


(isa isa links)

(())

(1)



(2)



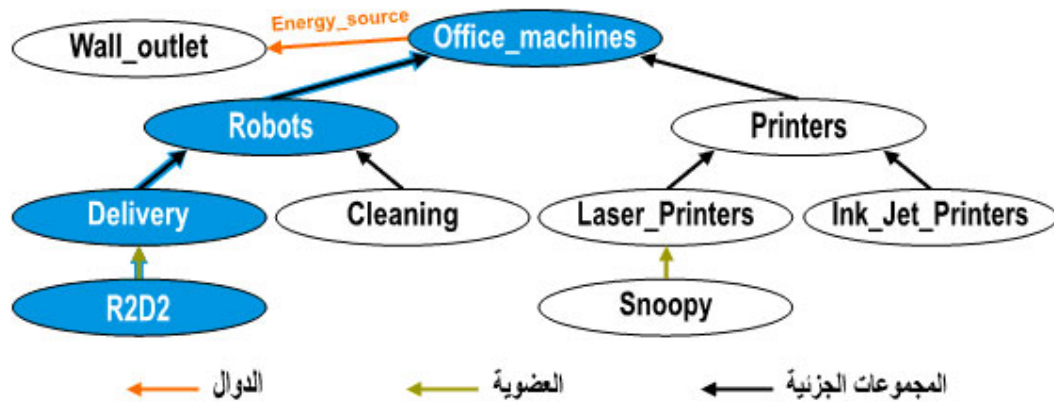
B

:A

(B) B : A

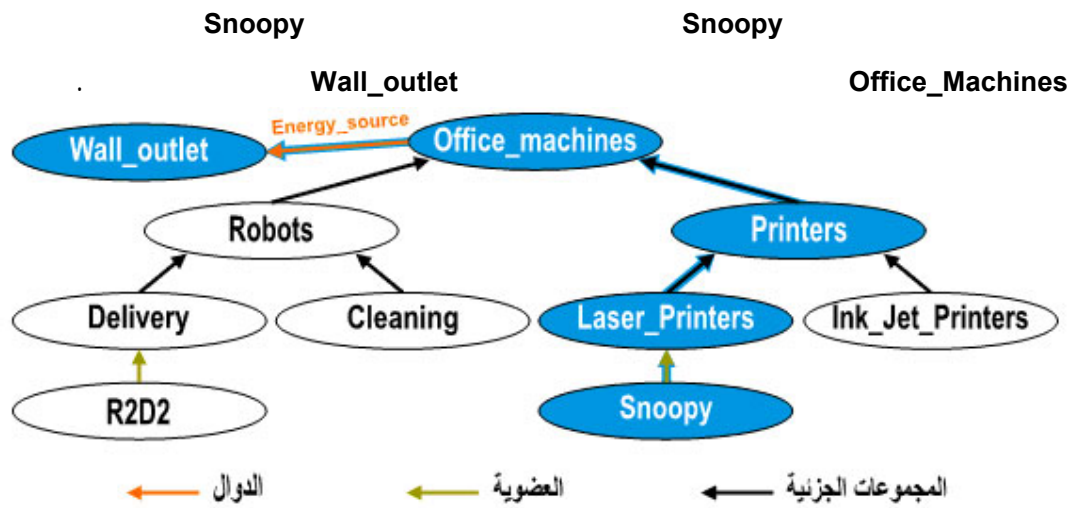
Office_Machine

R2D2

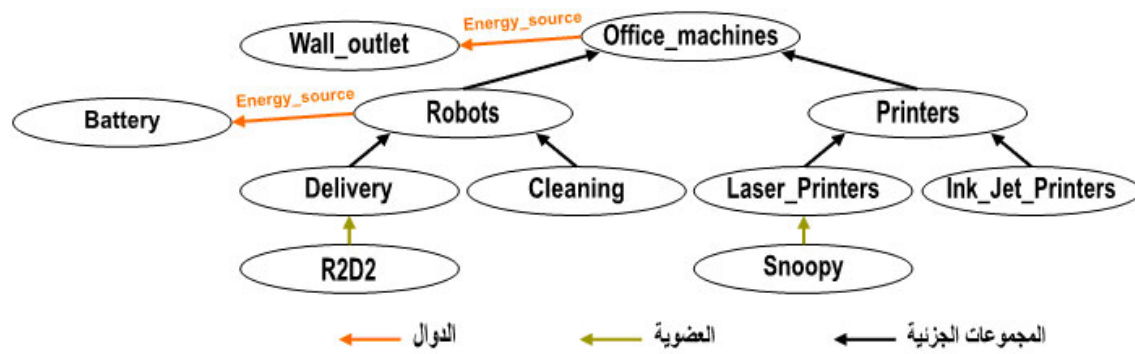


A

A



by default



()

)

.(

)

(

:

R2D2

R2D2

R2D2

()

Office_machines

Energy_source

Wall_outlet

.Battery

Robots

Energy_source

lists

:

:

:

الغرض	الوصفة	قيمة الوصفة
Astérix	المهنة	محارب
Obélix	الحجم	كبير جداً
Idéfix	الحجم	صغير
Panoramix	الحكمة	لا نهائية

OAV (- -)

.heuristics ()

part-of


is-a

AKO

a-kind-of

:

:




“Ahmad gave the book to Mona”

```
is_a(Action, give);
Tense(Action, past);
Subject(Action, Ahmad)
Obj1(Action, Mona)
Obj2(Action, book).
```


.3

Conceptual Dependencies :



Schank

() Ahmad gave the book to Mona :



Primitives

:ATRANS

:P

.receiver

:R

.object


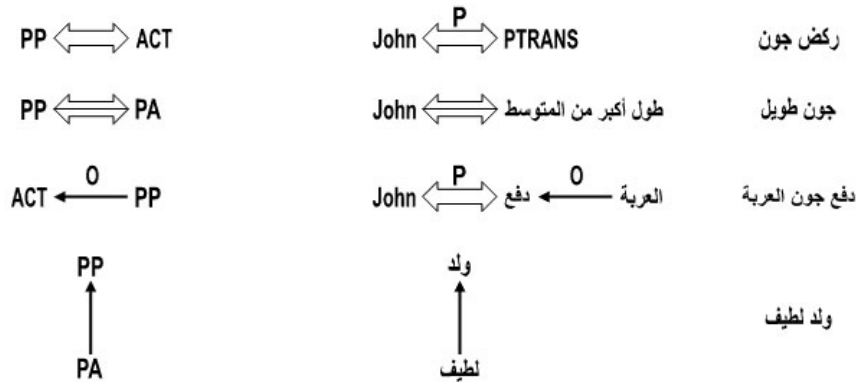
:O

Arabic Natural Language Processing

(www.ictis07.org :) ictis'07

April 2007

	:	
steal	take	give
	:	Abstract Transfer :ATRANS
		...
go	:	Physical Transfer :PTRANS
		...
...	push	:PROPEL
...	kick	:MOVE
...	throw	:GRASP
...	eat	:INGEST
...	cry	:EXPEL
...	say	:MTRANS
...	decide	:MBUILD
...	sing,	:SPEAK
...	listen	:ATTEND
	:	
(...)	Actions :ACT
(..)	Picture Producers :PP
(..)		Action Assistant :AA
(..)		Picture Assistant :PA
	:	



:

(...)

.ATRANS

:

:()

t: تحول أو انتقال
K: مستمر Continuous
Delta أو **D**: دائم eternal

f: المستقبل future
tf: تحول منته finished transition
nil: الحاضر
c: شرطي conditional

P: الماضي past
ts: التحول البدئي start transition
?: استفهامي
/: نفي

:

.

.

:

..

:

record

```

:
( slots' filling )
( )

```

Frames .4

meta-)

:1975 Marvin Minsky (knowledge

() "

"

"When one encounters a new situation (or makes a substantial change in one's view of a problem) one selects from memory a structure called a 'frame'. This is a remembered framework to be adapted to fit reality by changing details as necessary."

Frame name

Printers

Subset_of: Office_machies

Superset_of: {Laser_Printer,

slots Ink_jet_printers}

Energy_source: Wall_outlet

Creator: John_Jones

Date: 16_aug_91

slot

slot names

slot fillers

slot names

slot fillers

default values

meta knowledge

```

:
)
:(

```

Quantas Boarding Pass	Air New Zealand Boarding Pass
الشركة: Quantas	الشركة : Air New Zealand
اسم المسافر: Mr. Black	اسم المسافر : Mr. White
الرحلة: Q 101	الرحلة : NZ 101
التاريخ: 12 Dec	التاريخ : 13 Dec
المقعد: 24A	المقعد : 25A
من: Melbourne	من : Melbourne
إلى: Sydney	إلى : Christchurch
ساعة ركوب الطائرة: 0600	ساعة ركوب الطائرة : 1800
بوابة: 4	بوابة : 7

-
-
-
-
-
-
-
-
-

CLASS: Boarding Pass
 [Str]: شركة النقل
 [Str]: اسم المسافر
 [Str]: الرحلة
 [Str]: التاريخ
 [Str]: المقعد
 [Str]: من
 [Str]: إلى
 [Num]: ساعة ركوب الطائرة
 [Num]: بوابة

:Class-Frame
 Class of computers .
 :Instance-Frame ()
 My_computer .

- ◀
- ◀
- ◀

.is-a

:)

.(

- ◀
- ◀
- ◀

	generic	
	:	
.(:) is-a, a-kind-of	:Generalization
.(:) part-of, whole-part	:Aggregation
X	:)	:Association
	.(X
	:	
	()	inherent
	.()
	:	
	!demons	methods
demon	:	
:	:	
	IF-THEN	
	when-needed	•
	when-changed	•
	:	
	.goals	
	:	
	demons	
	.bottom-up	
	.top-down	
(meta knowledge)	
.Backward Chaining		
"when needed	"	
:)	
	(. " "	
	:	

.	➤
()	➤
.	➤
:	➤
.	➤
.	➤
.	➤
.demons methods	➤
:	
.	.1
.	.2
.	.3
.	.4
.(when changed when-needed) demons	.5
.	.6
.	.7
Buy Smart :	
() :	➤
.	
:	
	•
	•
	•
	•
	•
:	
	•

(..)

•

•

•

•



Property

•

•

•

CLASS: Property	
[Str] Area:	
[Str] Suburb:	
[N] Price:	
[Str] Type:	
[N] Bedrooms:	
[N] Bathrooms:	
[Str] Construction:	
[Str] Phone:	
[Str] Pictfile:	
[Str] Textfile:	
[N] Instance Number:	

.Instances

:



:

INSTANCE: Property 1	
<i>Class:</i>	<i>Property</i>
[Str] Area:	دمشق
[Str] Suburb:	برزة
[N] Price:	1640000
[Str] Type:	شقة
[N] Bedrooms:	3
[N] Bathrooms:	1
[Str] Construction:	بناء حديث
[Str] Phone:	(03) 6226 4212
[Str] Pictfile:	house01.bmp
[Str] Textfile:	house01.txt
[N] Instance Number:	1

INSTANCE: Property 2	
<i>Class:</i>	<i>Property</i>
[Str] Area:	دمشق
[Str] Suburb:	مهاجرين
[N] Price:	1500000
[Str] Type:	شقة
[N] Bedrooms:	3
[N] Bathrooms:	1
[Str] Construction:	قديم
[Str] Phone:	(03) 6226 1416
[Str] Pictfile:	house02.bmp
[Str] Textfile:	house02.txt
[N] Instance Number:	2

.Display

:



:



Buy Smart

Select the most important things you are looking for in your property:

Suburb	Bedrooms	Maximum Price
All Suburbs	Any number of bedrooms	No maximum
Central Suburbs	One bedroom	\$50,000
Eastern Shore	Two bedrooms	\$100,000
Northern Suburbs	Three bedrooms	\$150,000
Southern Suburbs	Four bedrooms or more	\$200,000
		\$250,000
		\$300,000
		\$350,000
		\$400,000
		\$500,000
		\$1,000,000
		\$2,000,000

Property Type	Bathrooms
All property types	Any number of bathrooms
House	One bathroom
Unit	Two bathrooms
Townhouse	Three bathrooms or more

Help Restart Search

When needed & When :demon methods : .changed

.when needed & when changed
 .pattern matching

demon

.5

.context scenario script
 by-default slots

(Schank, 1977)
 :Script

F : ●

.O M C W S : ●

S S : ●

() S S O S : ●

<p>Script: RESTAURANT Track: Coffee Shop Props: Tables Menu F = Food Check Money</p> <p>Roles: S = Customer W = Waiter C = Cook M = Cashier O = Owner</p>	<p>Scene 1: Entering</p> <p>S PTRANS S into restaurant S ATTEND eyes to tables S MBUILD where to sit S PTRANS S to table S MOVE S to sitting position</p> <hr/> <p>Scene 2: Ordering</p> <p>(Menu on table) (W brings menu) (S asks for menu) S PTRANS menu to S S MTRANS signal to W W PTRANS W to table W PTRANS W to menu W ATRANS menu to S S MTRANS food list to CP(S) *S MBUILD choice of F S MTRANS signal to W W PTRANS W to table S MTRANS "I want F" to W W PTRANS W to C W MTRANS (ATRANS) to C</p>
<p>Entry conditions: S is hungry. S has money.</p> <p>Results: S has less money O has more money S is not hungry S is pleased (optional)</p>	<p>C MTRANS "no F" to W W PTRANS W to S W MTRANS "no F" to S (go back to ") or (go to Scene 4 at no pay path)</p> <p>C DO (prepare F script) to Scene 3</p>
	<p>Scene 3: Eating</p> <p>C ATRANS F to W W ATRANS F to S S INGEST F</p> <p>(Option: Return to Scene 2 to order more; Otherwise, go to Scene 4)</p>
	<p>Scene 4: Existing</p> <p>S MTRANS to W (W ATRANS check to S W MOVE (write check) W PTRANS W to S W ATRANS check to S S ATRANS tip to W S PTRANS S to M S ATRANS money to M (No pay path) S PTRANS S to out of restaurant</p>

Generic RESTAURANT Frame

Specialization-of: Business-Establishment

Types:

range: (Cafeteria, Fast-Food, Seat-Yourself, Wait-To-Be-Seated)

default: Seat-Yourself

if-needed: IF plastic-orange-counter THEN Fast-Food,
IF stack-of-trays THEN Cafeteria,
IF wait-for-waitress-sign or reservations-made THEN Wait-To-Be-Seated,
OTHERWISE Seat-Yourself.

Location:

range: an ADDRESS

if-needed: (Look at the MENU)

Name:

if-needed: (Look at the MENU)

Food-Style:

range: (Burgers, Chinese, American, Seafood, French)

default: American

if-added: (Update Alternatives of Restaurant)

Times-of-Operation:

range: a Time-of-Day

default: open evenings except Mondays

Payment-Form:

range: (Cash, CreditCard, Check, Washing-Dishes-Script)

Event-Sequence:

default: Eat-at-Restaurant Script

Alternatives:

range: all restaurants with same Foodstyle

if-needed: (Find all Restaurants with the same Foodstyle)

[Rogers 1999]

()

EAT-AT-RESTAURANT Script

Props: (Restaurant, Money, Food, Menu, Tables, Chairs)

Roles: (Hungry-Persons, Wait-Persons, Chef-Persons)

Point-of-View: Hungry-Persons

Time-of-Occurrence: (Times-of-Operation of Restaurant)

Place-of-Occurrence: (Location of Restaurant)

Event-Sequence:

first: Enter-Restaurant Script

then: if (Wait-To-Be-Seated-Sign or Reservations)
then Get-Maitre-d's-Attention Script

then: Please-Be-Seated Script

then: Order-Food-Script

then: Eat-Food-Script unless (Long-Wait) when Exit-Restaurant-Angry Script

then: if (Food-Quality was better than Palatable)
then Compliments-To-The-Chef Script

then: Pay-For-It-Script

finally: Leave-Restaurant Script

[Rogers 1999]

:

.1

()

C B A

B B A

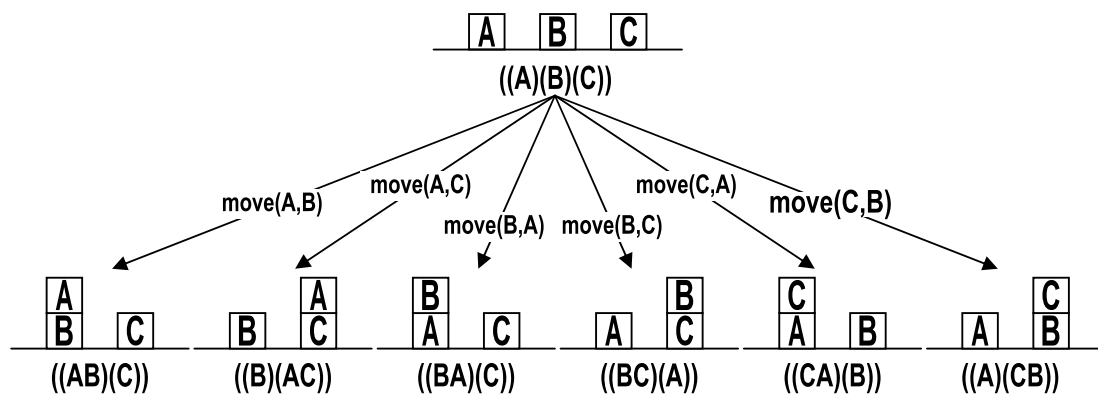
C C




x

y

move(x, y)





Graph

nodes

arcs

"directed graph"

successor n_j n_j n_i


parent () n_i n_i (

.1

((A)(B)(C)) :

((ABC))

{move(B,C),move(A,B)}



:

)

.()

(

B

A

:

A


B

C

:

C

{move(A, Floor), move(B, A), move(C, B)}



2.



عنونة العقد للبحث عن الهدف
(البحث الشامل)

"expansion"

)

:

—

(

.i < j

j

i

.(

)

()

()

.root

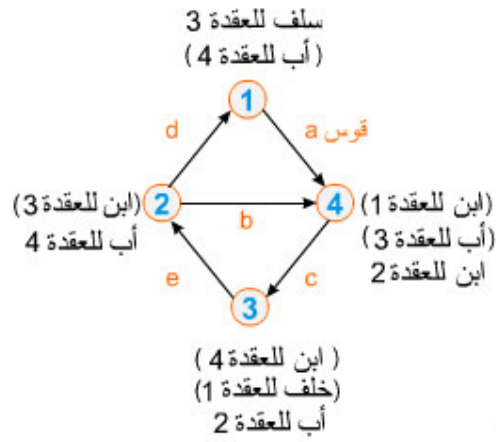
depth

()


.1

()

تكوين البيان



تكوين الشجرة



.uninformed

.heuristic ()

" " heuriskein

heuristic()
("!" ") Eureka!

Uninformed

:Open

:Close

.()

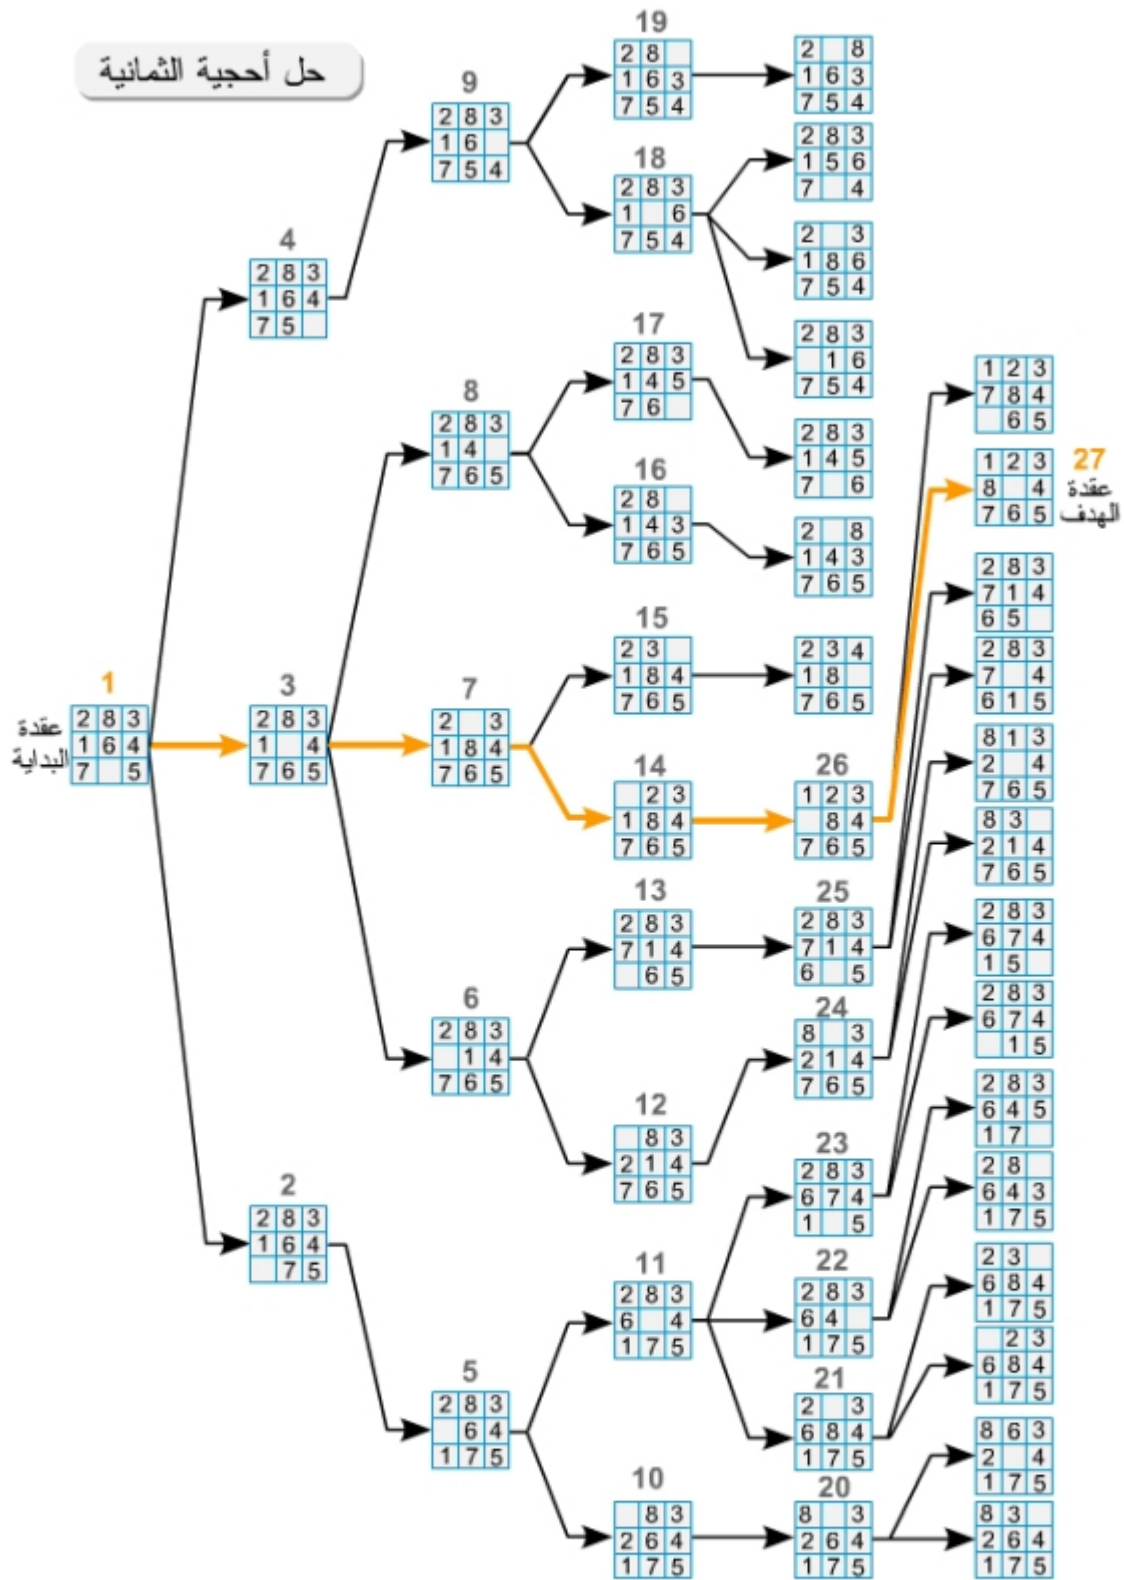
ربما تكون أبسط إجرائية بحث عمياء هي إجرائية البحث عرضاً_أولاً. تولد هذه الإجرائية بيانَ فضاء حالة شاملاً بتطبيق جميع المؤثرات الممكنة على عقدة البداية، ثم بتطبيق جميع المؤثرات الممكنة على جميع خلف عقدة البداية المباشرة، ثم على خلفها، وهلم جرا. يجري البحث بانتظام نحو الأسفل انطلاقاً من عقدة البداية. ولأننا نطبق جميع المؤثرات الممكنة على عقدة في كل خطوة، من المناسب ضمها جميعها في دالة تسمى دالة الخلف **Successor function**. عندما نطبق دالة الخلف على عقدة ما، فإنها تولد مجموعة العقد الكاملة التي من الممكن توليدها إذا طبقنا جميع المؤثرات القابلة للتطبيق على هذه العقدة. يسمى تطبيق دالة الخلف على العقدة: توسيع **expanding** العقدة.

للمجموعة **Open** بنية الرتل **FIFO**

يعتبر البحث ذو التكلفة الموحدة ضرباً من البحث عرضاً_أولاً، حيث تتوسع العقد انطلاقاً من عقدة البداية على طول "الحافات" ذات التكلفة المتساوية عوضاً عن الحافات ذات العمق المتساوي. فإذا تطابقت تكاليف جميع الأقواس في البيان (ولنقل تساوي 1)، فإن البحث الموحد التكلفة يصبح البحث عرضاً_أولاً ذاته. ويمكن اعتبار البحث الموحد التكلفة، بدوره، حالة خاصة من إجرائية البحث التجريبي (الكسبي)، الذي سوف نشرحه لاحقاً.

يبين الشكل حل أحجية الثمانية للانتقال من حالة البداية إلى حالة الهدف المرتبة المبينة بالشكل بحيث ننقل في كل مرة مربعاً إلى مكان فارغ مجاور.

حل أحجية الثمانية



البحث عمقا_أولا

يولد البحث عمقا_أولا خلفا واحدا لعقدة ما في كل مرة وذلك بتطبيق مؤثرات خاصة. ويترك أثر في

كل عقدة للإشارة إلى أنه يمكن تطبيق مؤثرات أخرى إضافية عليها عند الحاجة. عند كل عقدة، يجب اختيار، المؤثر الذي سيطبق أولاً، والمؤثر الذي يليه، وهلم جرا. وما إن يولد الخلف، حتى يولد خلفه وهلم جرا. ولكي نمنع إجرائية البحث من الاستمرار إلى عقد غير محدودة العمق بالنسبة إلى عقدة البداية، نستعمل حدا للعمق **depth bound**، حيث لا يجري توليد أي خلف عمقه أكبر من حد العمق هذا. (يفترض ألا تقع جميع عقد الهدف وراء حد العمق هذا). يسمح لنا هذا الحد بتجاهل أجزاء من بيان البحث تأكد عدم احتوائها على عقدة هدف قريبة إلى حد كاف.

للمجموعة Open بنية المكس LIFO

من الملاحظ أن البحث "عمقا_أولاً" لا يضطرنا إلا إلى حفظ جزء من شجرة البحث الذي يضم المسار المكتشف إلى الآن، إضافة إلى آثار العقد التي لم توسع كاملاً بعد على طول هذا المسار. يتناسب حجم الذاكرة المطلوب في البحث عمقا_أولاً، خطياً مع حد العمق. ومن مساوئ البحث عمقا_أولاً، هو أن العثور على هدف ما، لا يضمن كون المسار إلى هذا الهدف ذا طول أصغري. تكمن مشكلة أخرى في ضرورة سبر جزء كبير من فضاء البحث حتى نجد هدفاً سطحياً (ضاحلاً) إذا كان هذا الهدف وحيداً وخلفاً لعقدة سطحية يأتي توسيعها متأخراً في الإجرائية.

3. بيان المسائل الجزئية

أحياناً يمكن تقسيم المسألة، التي نود البحث عن حل لها، إلى مجموعة من المسائل الجزئية، بحيث يكون البحث عن حل لأحد المسائل الجزئية أسهل من المسألة الأساسية. ثم تقسيم المسائل الجزئية إلى مسائل أبسط إلى أن نصل إلى مسائل أولية بسيطة محلولة. مثل مسألة أبراج هانوي.

في هذه المسألة، لدينا ثلاثة محاور عمودية، يتوضع على المحور الأول n قرصاً متدرجة في أقطارها، والمسألة هي نقل الأقراص إلى المحور الثالث، بحيث ننقل قرصاً واحداً في كل مرة، وبحيث لا نضع أي قرص فوق قرص أصغر منه قطراً.

لعرض مثال تطبيقي لحل مسألة أبراج هانوي، قم بزيارة الموقع:

<http://www.mazeworks.com/hanoi>

تجزاً مسألة أبراج هانوي كما يلي:

1. نقل $n-1$ قرصاً من المحور الأول إلى المحور الثاني.
2. نقل القرص الكبير المتبقي من المحور الأول إلى المحور الثالث.
3. نقل $n-1$ قرصاً من المحور الثاني إلى المحور الثالث.

يجب تحديد كل مما يلي:

◀ حالات المسألة: الحالة الابتدائية والحالات العابرة.

➤ الهدف المطلوب الوصول إليه.

➤ مؤثرات التحويل المختارة.

يمكن تمثيل المسألة إما بوساطة بيان الحالات أو بوساطة بيان المسائل الجزئية. بيان الحالات درسناه سابقاً، أما بيان المسائل الجزئية، فما يميزه هو أن المؤثرات ليست مؤثرات ثنائية تحول حالة إلى أخرى، وإنما مؤثرات متعددة القيمة تحول حالة إلى مجموعة من الحالات، يمثل هذا النوع من المسائل ببيان **and-or**.

يمكن أن تكون المسائل الجزئية:

➤ إما واجبة الترتيب، أي ترتيب حل المسائل الجزئية مفروض،

➤ أو مستقلة، لا يهم فيها ترتيب حل المسائل الجزئية، بل يمكن استخدام مفاهيم المعالجة التفرعية لإيجاد الحل.

4. الشجرة **and-or**

عند تجزئة مسألة إلى عدة مسائل جزئية، قد يكون لدينا عدة طرق لحل المسألة الأساسية **M1 or M2** **or M3**، يستوجب كل منها حل مجموعة من المسائل الجزئية:

M1: OP11 and OP12 and OP13

M2: OP21 and OP22 and OP23

M3: OP31 and OP32 and OP33

في هذه الحالة تكون شجرة الحل هي شجرة **and-or**.

لا يكون حل المسألة في البيان **and-or** بيانا كاملا وإنما جزئيا بحيث يكون:

➤ جذر البيان الجزئي هو جذر البيان الكامل ذاته.

➤ لا ينطلق من عقدة **or** سوى قوس وحيد (ليصل إلى العقدة **and**)

➤ تنطلق من العقدة **and** جميع الأقواس الناتجة عن هذه العقدة ذاتها في البيان **and-or** الكامل ذاته. (كل أوراق البيان الجزئي هي أوراق نجاح).

إن خوارزميات البحث في البيانات **and-or** أكثر تعقيدا من البحث في بيانات الحالات لأن الحلول التي نبحث عنها ليست طرقا وإنما بيانات جزئية تتمتع بالخواص التالية:

➤ جذرها عقدة **or** تمثل المسألة الأساسية.

➤ لكل عقدة **or** ابن وحيد يمثل عقدة **and** (إحدى تجزئات المسألة الأصلية).

➤ لعقدة **and** كل الأبناء الخاصة بها.

مسار **or** لا يُمثل بسهولة باستعمال المؤثرات (**fathers**). الخيار بين الحلول الجزئية يعتمد غالبا على كلفة هذه الحلول، وقد يعتمد على كسبيات (تجربيات) لإيجاد هذه الكلفة.

5. البحث التجريبي

تشبه إجراءات البحث هنا إجراءات البحث عرضاً_أولاً، غير أن البحث لا يجري بتجانس بين خلف عقدة البداية؛ وعوضاً عن ذلك، يجري البحث بالمفاضلة بين العقد حيث تشير التجريبية : وهي معلومات خاصة بالمسألة، إلى العقد التي يمكن أن تكون في المسار الأفضل إلى الهدف. نسمي هذه الإجراءات إجراءات الأفضل_أولاً أو إجراءات البحث التجريبي. وفيما يلي الفكرة الأساسية لهذه الإجراءات.

1. لتكن لدينا دالة تجريبية (تقويم)، \hat{f} ، لتساعدنا على اختيار العقدة الفضلى لتوسيع العقدة التالية. تعتمد هذه الدالة على معلومات خاصة بمجال المسألة. وهي دالة تقويم حقيقية لأوصاف الحالة.
2. وسع بعد ذلك العقدة التالية، n ، وهي تلك التي لها أصغر قيمة لـ $\hat{f}(n)$. حل الروابط اعتباطياً. (توسيع عقدة يعني إنتاج جميع خلف هذه العقدة).
3. أنه البحث عندما تصبح العقدة التالية المراد توسيعها هي عقدة الهدف. يستطيع الإنسان غالباً تحديد دوال تقويم جيدة من أجل البحث بطريقة الأفضل_أولاً. على سبيل المثال، في أحجية الثمانية، يمكننا محاولة استعمال عدد المربعات التي في غير مكانها مقياساً لجودة وصف الحالة:

عدد المربعات التي في غير مكانها (مقارنة بالهدف) $\hat{f}(n)$

يمكن أن نعتبر:

$$\hat{f}(n) = \hat{g}(n) + \hat{h}(n)$$

حيث:

$\hat{g}(n)$ هي تقدير "لعمق" n في البيان (أي، طول أقصر مسار من البداية إلى n)،

$\hat{h}(n)$ هي تقويم تجريبي للعقدة n .

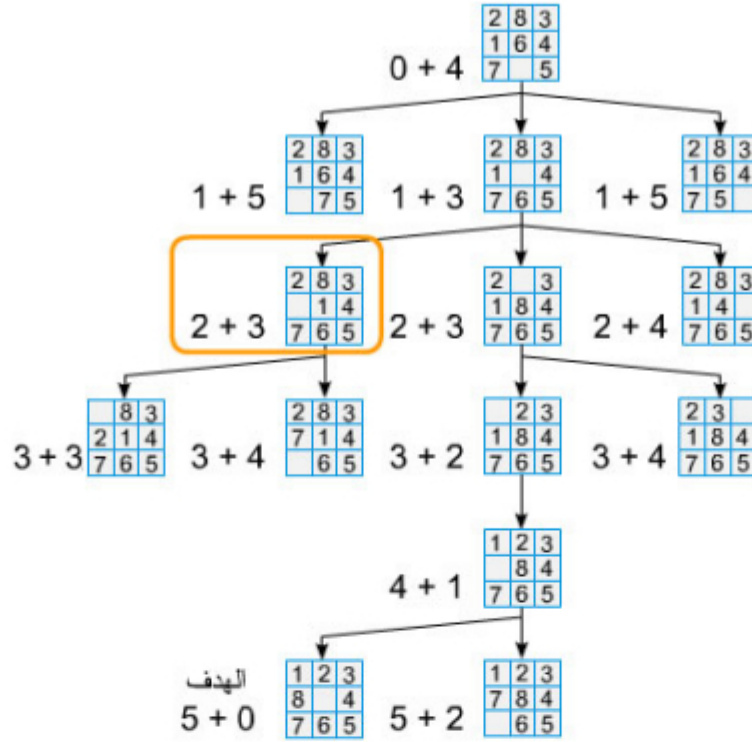
فإذا جعلنا، كما في السابق

عدد المربعات التي هي في غير مكانها (مقارنة بالهدف) $\hat{h}(n)$

وأخذنا

عمق العقدة n في بيان البحث $\hat{g}(n)$

حصلنا على البيان التالي:



خوارزميات البحث في بيان graphsearch

1. أنشئ شجرة بحث، Tr ، مكونة فقط من عقدة البداية، n_0 . ضع n_0 في قائمة مرتبة تسمى $OPEN$.
2. أنشئ قائمة تسمى $CLOSED$ تكون فارغة في البداية.
3. إذا كانت $OPEN$ فارغة، اخرج بالنتيجة: إخفاق.
4. اختر العقدة الأولى في $OPEN$ ، واحذفها من $OPEN$ ، وضعها في $CLOSED$. سم هذه العقدة n .
5. إذا كانت n عقدة هدف، اخرج بنجاح مع الحل الذي حصلت عليه برسم مسار راجع على طول الأقواس في Tr من n إلى n_0 . (تنشأ الأقواس في الخطوة 6).
6. وسع العقدة n ، بتوليد مجموعة، M ، من الخلف. أرس M باعتبارها خلفا لـ n في Tr بإنشاء الأقواس من n إلى كل عنصر من M . ضع هذه العناصر من M في $OPEN$.
7. أعد ترتيب القائمة $OPEN$ ، إما وفق بعض المخططات الاعتبائية أو وفق استحقاق تجريبي.
8. عد إلى الخطوة 3.

يمكن استعمال هذه الخوارزمية لتنفيذ بحث الأفضل_أولا، أو البحث عرضا_أولا، أو البحث عمقا_أولا. في البحث عرضا_أولا، نضع العقد الجديدة ببساطة في نهاية $OPEN$ (الداخل أولا، يخرج أولا، أو $FIFO$)، ولا يعاد ترتيب العقد. في البحث بطريقة عمقا_أولا، نضع العقد الجديدة في بداية $OPEN$ (الداخل أخيرا، يخرج أولا، أو $LIFO$). في بحث الأفضل_أولا (يسمى أيضا البحث التجريبي)،

يعاد ترتيب OPEN وفق استحقاق تجريبي للعقد.

الخوارزمية A*

هي حالة خاصة من خوارزميات البحث بإستراتيجية الأفضل_أولا، تعتمد على تابع تقويم $f=h+g$. تابع التقويم f المطبق على عقدة n هو تقدير للكلفة f للطريق الأمثل من العقدة الابتدائية n_0 إلى عقدة هدف مرورا بـ n .

نعرف لكل عقدة n :

$g(n)$: كلفة الطريق الأمثل من n_0 إلى n (يساوي اللانهاية إذا لم يوجد أي طريق).

$h(n)$: كلفة الطريق الأمثل من n إلى الهدف

نستخدم تقديرا لهذه التوابع $g(n)$ و $h(n)$ على التوالي. ترتب القيم المرشحة للتوسيع بحسب القيم المتصاعدة لـ f ومن ثم التنازلية لـ g . يمكن أن تتغير قيم g أثناء البحث، حين نجد عقدا أفضل، أما h فسكونية.

ثمة خوارزميات تجريبية أخرى نستخدمها في برمجة الألعاب يمكن الرجوع إليها في مراجع الفصل.

6. مراجع البحث

➤ كتاب الذكاء الصناعي

➤ كتاب جامعي: "خوارزميات البحث الذكية"، تأليف د. بسام الكردي ود. باسل الخطيب ، كلية المعلوماتية.

الفصل الخامس: المعرفة والتفكير المتلبسين

لا يتوفر لدينا، في غالب الأحيان، سوى معارف غير مؤكدة عن المهام الواجب تنفيذها وعن المحيط .
تسمح لنا العبارات مثل $P \vee Q$ بالتعبير عن الشك: أيهما الصحيح P أم Q ؟ إلا أننا لم نصيف بعد، كيف يمكننا تمثيل درجة توثقنا **how certain** من P أو Q .

يمكننا، في المنطق العادي، استنتاج Q من P ومن $P \supset Q$. والسؤال هو، هل توجد تقانات استدلال مماثلة عندما تكون المعلومات غير مؤكدة؟ لقد استعملت صياغات متنوعة لتمثيل معلومات غير مؤكدة وإجراء محاكمة عليها. إن أكثر الصياغات تطورا (وقد يختلف الناس في أنها أكثر ملاءمة) هي التقانة التي تعتمد على الاحتمالات.

1. مراجعة الاحتمالات

لنفترض أن لدينا مجموعة من المتغيرات العشوائية V_1, V_2, \dots, V_k . نشير إلى الاحتمال المشترك **joint probability**، أن تأخذ المتغيرات V_1, V_2, \dots, V_k القيم v_1, v_2, \dots, v_k على الترتيب، بالتعبير $p(V_1=v_1, V_2=v_2, \dots, V_k=v_k)$.

نسمي التعبير $p(V_1, V_2, \dots, V_k)$ دالة الاحتمال المشترك **joint probability function** للمتغيرات V_1, V_2, \dots, V_k .

مثلا، في مسألة رمي قطعة نقود متوازنة (نشير إلى أحد الوجوه بالرمز **Head (H)** وللآخر بالرمز **(Tail (T)**)، يمكن أن يكون لدينا $p(H)=1/2$. فإذا رمينا قطعة النقود المتوازنة خمس مرات يمكن أن يكون لدينا مثلا:

$$p(H, T, T, H, T)=1/32$$

حيث $p(H, T, T, H, T)$ هي الاحتمال المشترك لتعطي أول تجربة رمي الحالة "وجه H"، والثانية الحالة "قفا T"، والثالثة "قفا T"، والرابعة "وجه H" والخامسة "قفا T".

يجب أن تحقق دوال الاحتمال المشترك خواص معينة، منها:

$$0 \leq p(V_1, V_2, \dots, V_k) \leq 1 \quad (a)$$

$$\sum p(V_1, V_2, \dots, V_k) = 1 \quad (b)$$

حيث تجري عملية الجمع على جميع قيم المتغيرات. وهكذا، فإنه في مثال قطعة النقود، فإن $p(H)=1/2$ متسقة مع الخصيصة (a). في حين أن هذه القيمة، وبمراعاة الخصيصة (b)، تقتضي أن يكون لدينا $p(T)=1/2$.

تعتمد كيفية إسناد الاحتمالات إلى قيم المتغيرات العشوائية على التقدير الشخصي للخبير في مجال التطبيق (أو على معالجة إدراكية لمعطيات المحسّات)، وكذلك تعتمد قيم احتمالات المتغيرات العشوائية

على تقدير الخبير أو على المعالجة الإدراكية. تقابل المتغيرات، في التطبيقات التي سنعالجها في هذا الفصل، فرضيات عن المجال. يمكن أن تكون هذه الفرضيات **True** أو **False**. ومن ثم تأخذ المتغيرات المقابلة القيم **True** أو **False**. يمكن أن تكون غير متوثقين من صحة واحدة أو أكثر من هذه الفرضيات؛ ونمثل عدم اليقين (الشك) هذا باحتمال قيم المتغيرات الموافقة.

سيكون من المفيد أن نؤطر عرض المفاهيم الهامة بمثال محدد. سنستخدم المثال التالي:

نأخذ ذرات الفرضيات **BAT_OK** و **MOVES** و **LIFTABLE** التي تقابل، على الترتيب، البطارية مشحونة تماما، والذراع يتحرك (حين يمكك الكتلة) والكتلة قابلة للحمل. نضيف إلى هذه الذرات الذرة **GAUGE**، التي يقصد منها أن تعني أن المقياس الذي يعطي حالة البطارية يشير إلى أن البطارية مشحونة شحنا كاملا. ولجعل مخططاتنا وصيغنا، أصغر حجما بعض الشيء، فإننا سنسمي هذه الذرات بالأحرف الأولى من أسمائها أي **B** و **M** و **L** و **G**. لنفترض الآن أننا لسنا واثقين من قيم هذه الذرات، أي **True** أم **False**. وقبل أن نقوم بأي عملية قراءة للمحسّات، لدينا معرفة سابقة باحتمالات التراكيب المختلفة لهذه القيم. فمثلا نستبعد أن تأخذ **M** قيمة **False** حين تكون بقية الفرضيات **True**.

نظرا لوجود أربعة متغيرات ذات قيم إثنائية فيوجد 16 احتمالا مشتركا لهذه المتغيرات، لكل منها الشكل:

$$p(B=b, M=m, L=l, G=g)$$

حيث تأخذ كل من **b** و **m** و **l** و **g** القيم **True** أو **False**.

على سبيل المثال، سنسرد بعضا من هذه الاحتمالات المشتركة في الجدول التالي:

(B, M, L, G)	Joint probability (الاحتمال المشترك)
(True, True, True, True)	0.5685
(True, True, True, False)	0.0299
(True, True, False, True)	0.0135
(True, True, False, False)	0.0007
(..., ..., ..., ...)	...

حين نعرف قيم جميع الاحتمالات (بالطبع قد لا يكون المصمم قادرا على تعيين الاحتمالات بمثل الدقة المعطاة بالجدول) المشتركة لمجموعة من المتغيرات العشوائية، يمكننا أن نحسب الاحتمال الهامشي **marginal probability** لأحد هذه المتغيرات العشوائية.

يعرف الاحتمال الهامشي **p(B=b)** مثلا بأنه مجموع كل قيم الاحتمالات المشتركة الثمانية من أصل القيم الست عشرة التي يكون فيها **B=b**.

$$p(B = b) = \sum_{B=b} p(B, M, L, G)$$

وباستخدام هذه الصيغة، نجد أن الاحتمال الهامشي **p(B=True)=0.95**، وهو مجموع القيم الثمانية

للاحتمالات المشتركة التي يكون فيها لـ **B** القيمة **True**.

يمكن أيضا حساب الاحتمالات المشتركة من مرتبة أدنى، بحساب جمع مناسب على الاحتمالات المشتركة الكاملة. على سبيل المثال، الاحتمال المشترك $p(B=b, M=m)$ يساوي مجموع قيم جميع الاحتمالات المشتركة الأربعة التي يكون فيها **B=b** و **M=m**:

$$p(B = b, M = m) = \sum_{B=b, M=m} p(B, M, L, G)$$

وينتج عن ذلك، أنه عندما نعرف قيم الاحتمالات المشتركة بمرتبة أقل، يمكن أن نستخدمها لحساب الاحتمالات الهامشية والاحتمالات المشتركة من مرتبة أقل. وهكذا، على سبيل المثال:

$$p(B = b, M = m) = \sum_{B=b, M=m} p(B, M, L) \quad \text{و} \quad p(B = b) = \sum_{B=b} p(B, M)$$

سنستخدم عند التعامل مع متغيرات الفرضيات (التي قيمها **True** أو **False**) تدويننا مختزلاً في غالب الأحيان. على سبيل المثال، عوضاً عن كتابة $p(B=True, M=False)$ سنكتب $p(B, \neg M)$.

إلا أنه عندما يكون لدينا مجموعة كبيرة من المتغيرات العشوائية، فإن مهمة تحديد كل الاحتمالات المشتركة، تصبح غير قابلة للتعبق (للتحقيق) عملياً. ولحسن الحظ، تحقق الاحتمالات المشتركة، في أكثر التطبيقات، شروطاً خاصة معينة تمكّن من تحديدها وإجراء حسابات عليها.

نريد أن نكون قادرين على استخدام المعلومات المتوفرة عن قيم بعض المتغيرات للحصول على احتمالات قيم بعض المتغيرات الأخرى. مثلاً، إذا كان ربوط حمل الكتل يجس أن ذراعه لا يتحرك، فربما يريد (مع معرفة هذه الحقيقة) حساب احتمال كون البطارية مشحونة. يسمى هذا النوع من الحسابات بالاستدلالات الاحتمالية **Probabilistic Inference** بالمماثلة مع طرائق الاستدلال المنطقية.

ندون دالة الاحتمال الشرطي لـ V_i بفرض أن V_j معطاة بـ $p(V_i|V_j)$ (مهما كانت قيم المتغيرات V_i و V_j)، ويعطى بـ:

$$p(V_i|V_j) = p(V_i, V_j) p(V_j)$$

حيث $p(V_i, V_j)$ هو الاحتمال المشترك لـ V_i و V_j ، و $p(V_j)$ هو الاحتمال الهامشي لـ V_j . ونرى من هذا التعبير أنه يمكننا أيضاً كتابة الاحتمال المشترك بدلالة الاحتمال الشرطي:

$$p(V_i, V_j) = p(V_i|V_j) p(V_j)$$

بالعودة إلى مثال حمل الكتل، يمكن أن نحسب احتمال كون البطارية مشحونة علماً أن الذراع لا يتحرك:

$$p(B = \text{True} | M = \text{False}) = p(B = \text{True}, M = \text{False}) / p(M = \text{False})$$

يمكن حساب البسط $p(B = \text{True}, M = \text{False})$ والمقام $p(M = \text{False})$ لهذا التعبير بجمع الاحتمالات

المشتركة المناسبة.

يمكن فهم الاحتمالات الشرطية باستعمال تفسير الاحتمال على أساس التواتر frequency. فتكون $p(M = \text{False})$ على سبيل المثال، هي نسبة عدد المرات التي لا تتحرك فيها الذراع إلى مجموع عدد المحاولات (في تجارب تخيلية تجرى عددا لا نهائيا من المرات). وعلى هذا فإن احتمال أن تكون البطارية مشحونة مع كون الذراع لا تتحرك يعطى بعدد المرات التي لم تتحرك، فيها الذراع مع كون البطارية مشحونة، مقسوما على عدد المرات التي لم تتحرك فيها الذراع. وبذلك، يكون الاحتمال الشرطي نسخة مقيسة عن الاحتمال المشترك. نلاحظ أن:

$$p(B) = p(B, M) + p(B, \neg M)$$

يمكننا أيضا الحصول على الاحتمالات الشرطية المشتركة لعدة متغيرات، مشروطة بعدة متغيرات أخرى. على سبيل المثال (باستعمال التدوين المختزل):

$$p(\neg G, B, \neg M, L) = p(\neg G, B, \neg M, L) / p(\neg M, L)$$

يمكن أيضا التعبير عن الاحتمال المشترك بدلالة سلسلة chain من الاحتمالات الشرطية. مثلا:

$$p(B, L, G, M) = p(B|L, G, M) p(L|G, M) p(G|M) p(M)$$

ولأن الطريقة التي نرتب فيها المتغيرات في دالة الاحتمال المشترك غير مهمة (بشرط الاحتفاظ بهذا الترتيب، ومعرفة كل العناصر) يمكننا أن نكتب ما يلي:

$$p(V_i, V_j) = p(V_i|V_j) p(V_j) = p(V_j|V_i) p(V_i) = p(V_j, V_i)$$

or

$$p(V_i|V_j) = p(V_j|V_i) p(V_i) / p(V_j)$$

هذه المعادلة الأخيرة هامة جدا وتدعى بقاعدة بايز Bayes' Rule.

كان بايز Reverend Thomas Bayes [Bayes 1763] أول من صاغ هذه القاعدة.

2. قاعدة بايز والمحاكمة باستخدامها

قاعدة بايز

$$P(A/B) = P(B/A) \cdot P(A) / P(B)$$

حيث:

$P(A)$ احتمال وقوع A .

$P(B)$ احتمال وقوع B .

$P(A/B)$ و $P(B/A)$ احتمالات شرطية

وذلك بافتراض A و B غير متعارضتين.

في حال كان حدوث A مشروطا بحدثين متعارضين B و $\neg B$. فقط. يكون لدينا:

$$P(A) = P(A/B) \cdot P(B) + P(A/\neg B) \cdot P(\neg B)$$

بالمشابهة إذا كان حدوث **B** مشروطا بحدثين متعارضين **A** و $\neg A$ فقط. يكون لدينا:

$$P(B) = P(B/A) \cdot P(A) + P(B/\neg A) \cdot P(\neg A)$$

بتعويض العلاقة السابقة في حساب $P(A/B)$ يمكن أن نكتب:

$$P(A/B) = P(B/A) \cdot P(A) / P(B) = P(B/A) \cdot P(A) / [P(B/A) \cdot P(A) + P(B/\neg A) \cdot P(\neg A)]$$

أمثلة على تطبيق قاعدة بايز

مثال (1):

احتمال النجاح في مادة الذكاء الصناعي هو

$$P(A) = 0.7$$

احتمال الحصول على علامة جيدة بالعمل هو

$$P(B) = 0.8$$

احتمال أن تكون علامة العمل جيدة علما أن الطالب نجح في الامتحان

$$P(B/A) = 0.9$$

ما هو احتمال النجاح في الامتحان إذا كانت علامة العمل جيدة؟

$$P(A/B) = ?$$

من القاعدة $P(A/B) = P(B/A) \cdot P(A) / P(B)$ نجد أن: $P(A/B) = 0.9 \cdot 0.7 / 0.8$

مثال (2):

احتمال ارتفاع الحرارة

$$P(A) = ?$$

احتمال الإصابة بالكريب هو

$$P(B) = 0.3$$

احتمال ارتفاع الحرارة بوجود الكريب

$$P(A/B) = 0.8$$

احتمال ارتفاع الحرارة بغياب الكريب

$$P(A/\neg B) = 0.4$$

وجود الكريب أو غيابه حدثان متعارضان.

احسب احتمال ارتفاع الحرارة.

$$P(A) = ?$$

نطبق قاعدة حدوث **A** مشروطا بحدثين متعارضين **B** و $\neg B$ فقط:

$$P(A) = P(A/B) \cdot P(B) + P(A/\neg B) \cdot P(\neg B)$$

المحاكمة

لنفترض إنه إذا كانت الفرضية **H** محققة وقع الحدث **E** باحتمال **P**. فنعرف:

الاحتمال القبلي **Prior Prob.**: الاحتمال غير المشروط للحدث بدون أي دليل على حدوثه أو عدمه

P(Event)

الاحتمال البعدي **Posterior Prob.**: الاحتمال الشرطي لوقوع الحدث بوجود بعض الأدلة $P(\text{Event} / \text{Evidence})$.

في حالة التشخيص نود حساب احتمال صحة فرضية التشخيص H_i اعتماداً على الأدلة (الأعراض) E_j . حيث لدينا الاحتمالات القبلية $P(H_i)$ والاحتمالات الشرطية $P(E_j/H_i)$ ونود حساب $P(H_i/E_j)$. فيكون:

$$p(H | E) = \frac{p(E | H).p(H)}{p(E | H).p(H) + p(E | \neg H).p(\neg H)}$$

في حالة النظم الخبيرة يحدد الخبير الاحتمالات القبلية $p(H), p(\neg H)$ والاحتمالات الشرطية $p(E | H), p(E | \neg H)$ ويجري حساب $p(H | E)$ من العلاقة السابقة. (فرضية واحدة ودليل واحد). إذا كان لدينا m فرضية $H_i, i=1, \dots, m$ و n دليل $E_j, j=1, \dots, n$ ، يجب أن تكون الأدلة متعارضة مثلي، وأن تكون الفرضيات شاملة أي:

$$p(H_i | E_1, \dots, E_n) = \frac{p(E_1, \dots, E_n | H_i).p(H_i)}{p(E_1, \dots, E_n)}$$

$$p(H_i | E_1, \dots, E_n) = \frac{p(E_1 | H_i).p(E_2 | H_i) \dots p(E_n | H_i).p(H_i)}{\sum_j p(E_1 | H_j).p(E_2 | H_j) \dots p(E_n | H_j).p(H_j)}$$

إذا كانت الأدلة مستقلة مثلي.

مثال على المحاكمة

نود دراسة احتمال نجاح طالب في مادة ما. لدينا الفرضيات التالية:

H_1 : النجاح في العملي وفي الامتحان.

H_2 : النجاح في العملي والرسوب في الامتحان.

H_3 : الرسوب في المادة.

أما الأدلة أو الملاحظات التي يمكن مراقبتها فهي:

E_1 : حضور جميع جلسات العملي.

E_2 : قضاء 3 ساعات يومياً في الكافيتيريا.

E_3 : دراسة المراجع المتعلقة بالمادة.

	Hypothesis		
	$i = 1$	$i = 2$	$i = 3$
$P(H_i)$.70	.10	.20
$P(E_1 H_i)$.80	.50	.10
$P(E_2 H_i)$.30	.50	.70
$P(E_3 H_i)$.70	.30	.05

أحد الخبراء بالمادة، أعطى الاحتمالات القبلية والشرطية المبينة في الجدول، والمطلوب حساب:

➤ $P(H_1/E_1)$ أي احتمال النجاح في العملي والامتحان بحضور جميع جلسات العملي.

$$P(H_1/E_1) = P(E_1/H_1).P(H_1) / PP$$

حيث:

$$PP = P(E_1/H_1). P(H_1) + P(E_1/H_2). P(H_2) + P(E_1/H_3). P(H_3)$$

بالحساب نجد:

$$PP = .7 \cdot .8 + .1 \cdot .5 + .2 \cdot .1 = .63$$

الكافيتريا يوميا. $P(H_3/E_2) P(H_1/E_1) = .56/.63 = .889$ أي احتمال الرسوب في المادة مع قضاء 3 ساعات في

$$P(H_3/E_2) = P(E_2/H_3) \cdot P(H_3) / PP_1$$

$$PP_1 = P(E_2/H_1) \cdot P(H_1) + P(E_2/H_2) \cdot P(H_2) + P(E_2/H_3) \cdot P(H_3)$$

بالحساب نجد:

$$PP_1 = .7 \cdot .3 + .1 \cdot .5 + .2 \cdot .7 = .4$$

العملي ودراسة المراجع. $P(H_1/E_1.E_3) P(H_3/E_2) = .14/.40 = .35$ أي احتمال النجاح بالعملي والامتحان مع حضور جلسات

$$P(H_1/E_1.E_2) = P(E_1/H_1) \cdot P(E_3/H_1) \cdot P(H_1) / PP_2$$

$$PP_2 = P(E_1/H_1) \cdot P(E_3/H_1) \cdot P(H_1) + P(E_1/H_2) \cdot P(E_3/H_2) \cdot P(H_2) + P(E_1/H_3) \cdot P(E_3/H_3) \cdot P(H_3)$$

بالحساب نجد:

$$PP_2 = .392 + .015 + .001$$

$$P(H_1/E_1.E_3) = .392/PP_2 = .961$$

تمرين: احسب احتمال النجاح بالعملي والامتحان في حال قضاء 3 ساعات يوميا في الكافيتريا.

حسنات ومساوئ المحاكمة باستخدام شبكات بايز

حسناتها:

لها أساس نظري.

لها مدلول واضح حين اتخاذ القرار.

مساوئها:

تحتاج إلى معطيات كثيرة وحسابات احتمالات.

قد لا تكون الأدلة الشخصية واحتمالاتها مقنعة.

الأدلة ليست دائما مستقلة.

الحسابات طويلة.

العلاقة بين الأدلة والفرضيات تختصر إلى أرقام.

3. الشك

يعرف الشك بأنه نقص في المعرفة الدقيقة التي تمكننا من الوصول إلى نتائج موثوقة. هذا النقص يمنع النظم الخبيرة على سبيل المثال من اتخاذ القرارات الصائبة.

عوامل اليقين هي تقنية استخدمت في عدد من النظم الخبيرة على رأسها MYCIN و PROSPCTOR. الفكرة هي أنه يمكن الوصول إلى نتائج أفضل باستخدام عدد أكبر من الاختبارات. هذه الاختبارات قد

تكون مكلفة بالزمن والمال.

يمكن أن يأتي الشك من معطيات محسات غير موثوقة، والإستراتيجية هي أنه من الأفضل اعتماد

Ray Simpson (1944)		Milton Hake (1968)	
Term	Mean value	Term	Mean value

Always	99	Always	100
Very often	88	Very often	87
Usually	85	Usually	79
Often	78	Often	74
Generally	78	Generally	74
Frequently	73	Frequently	72
Rather often	65	Rather often	72
About as often as not	50	About as often as not	50
Now and then	20	Now and then	34
Sometimes	20	Sometimes	29
Occasionally	20	Occasionally	28
Once in a while	15	Once in a while	22
Not often	13	Not often	16
Usually not	10	Usually not	16
Seldom	10	Seldom	9
Hardly ever	7	Hardly ever	8
Very seldom	6	Very seldom	7
Rarely	5	Rarely	5
Almost never	3	Almost never	2
Never	0	Never	0

معطيات تقريبية عوضاً عن انتظار المعطيات الدقيقة.

مصادر الشك

❖ قد لا يكون الخبير قادراً على اكتشاف الترابط

الوثيق بين الجزء الـ-شرطي (IF part) من

قواعده ونتائج هذه القواعد (THEN part).

❖ أحياناً يستخدم الخبير اللغة الطبيعية التي لا

تخلو من التباس في التعبير عن معرفته (مثل

أحياناً، غالباً، نادراً...). ولا يمكن تكمية هذه

الواصفات بأرقام ثابتة تدل على نسبة اليقين

بها. وإذا كان لدينا عبارة (أغلق الكتاب) ليس

شرطاً أن يكون واضحاً أي كتاب نقصد.

❖ قد تكون بعض المعطيات غير معروفة أو ناقصة. فعبارة (أدر المفتاح) لا تعني بالضرورة أننا

نعرف أي اتجاه نقصد، يجب إضافة مع عقارب الساعة أو عكسها مثلاً أو إلى اليمين أو اليسار.

❖ قد نضطر إلى ضم خبرات أكثر من خبير في مجال ما.

❖ قد يكون لدينا أخطاء تكرارية (من حساس أو بنتيجة دقة حسابات)، خطأ بقراءة حساس أو في

دقة القياس.

❖ قد يكون لدينا خطأ في المحاكمة (الاستنتاج والاستقراء ..)

مع أن الاستنتاج سليم عادة إلا أن قواعدها يمكن ألا تكون سليمة في صياغتها الأصلية فنستنتج نتائج

خاطئة، وقد تكون القاعدة صحيحة في غالب الأحيان ولكن ليس في كل الأحيان . فنعمم ولا نكون

متأكدين من صحة التعميم.

4. عوامل اليقين Certainty Factors

استخدمت عوامل اليقين في Mycin وهي أرقام تدل على اعتقاد الخبير بفرضية معينة:

❖ الرقم +1 يدل على يقين بالصحة.

❖ الرقم -1 يدل على يقين بالخطأ.

❖ الرقم 0 تدل على غياب اليقين بصحة أو خطأ الفرضية.

الرقم	دلالتة اللغوية
-1	أكيد لا
-0.8	تقريباً أكيد لا
-0.6	من المحتمل لا
-0.4	ربما لا
-0.2 to 0.2	غير معروف
+0.4	ربما نعم
+0.6	من المحتمل نعم
+0.8	تقريباً أكيد نعم
+1	أكيد نعم

➤ الرقم الموجب يدل على وجود أدلة تدعم الفرضية.

➤ الرقم السالب يدل على وجود أدلة تدحض الفرضية.

ويبين الجدول ترجمة مفردات اللغة الطبيعية بحسب هذه الأرقام.

يمكن أن تكون الحقائق مشكوك بها أو القواعد أو كليهما. ويجب حساب عوامل اليقين للنتيجة (نتيجة القواعد) بناء عليها.

حساب معامل اليقين لمقدمة قاعدة

إذا كانت المقدمة هي مجموعة حقائق يفصل بينها AND فمعامل اليقين هو أصغر معامل يقين لهذه الحقائق.

$$CF(A \text{ and } B) = \min (CF(A), CF(B))$$

إذا كانت المقدمة هي مجموعة حقائق يفصل بينها OR فمعامل اليقين هو أكبر معامل يقين لهذه الحقائق.

$$CF(A \text{ or } B) = \max (CF(A), CF(B))$$

معامل اليقين لنفي حقيقة هو نفي معامل اليقين للحقيقة.

$$CF(\neg A) = - CF(A)$$

مثال: لنفترض أن $CF(A) = 0.3$ ، $CF(B) = 0.5$ ، $CF(C) = 0.4$ ، $CF(D) = -0.7$ فيكون:

$$CF(A \text{ and } B \text{ or } C \text{ and not}(D)) = \max(\min(0.3, 0.5), \min(0.4, 0.7)) = \max(0.3, 0.4) = 0.4$$

لنفترض أن قاعدة تقول: إذا كانت السماء صافية فيكون التنبؤ الجوي بجو صحو، وأن معامل اليقين لهذه القاعدة 0.6، فإذا كان معامل اليقين لكون السماء صافية هو 0.5 فإن معامل اليقين ليكون الجو صحو هو: $0.6 \times 0.5 = 0.3$.


لنفترض الآن ما يلي: $P1 \Rightarrow Q1$ ، $P2 \Rightarrow Q1$ ، وأنا حسبنا معامل اليقين لـ $Q1$ من القاعدة الأولى هو cf_1 ، وأن معامل اليقين لـ $Q1$ من القاعدة الثانية هو cf_2 ، فعندها يمكن حساب معامل اليقين النهائي لـ $Q1$ يعطى بالعلاقة التالية:

$$cf(cf_1, cf_2) = \begin{cases} cf_1 + cf_2 \times (1 - cf_1) & \text{if } cf_1 > 0 \text{ and } cf_2 > 0 \\ \frac{cf_1 + cf_2}{1 - \min[|cf_1|, |cf_2|]} & \text{if } cf_1 < 0 \text{ or } cf_2 < 0 \\ cf_1 + cf_2 \times (1 + cf_1) & \text{if } cf_1 < 0 \text{ and } cf_2 < 0 \end{cases}$$

5. المنطق العائم

يهتم المنطق العائم باستخدام قيم قائمة تلتقط معاني الكلمات والمحاکمات البشرية واتخاذ القرار. وهي مثلا حين يستخدم الخبير كلمات مثل عادة، على الأغلب، نادرا... الخ. ويجري استخدام قواعد شرطية إلا إنها قائمة مثل:

إذا كانت السرعة عالية فمسافة التوقف طويلة
إذا كانت السرعة منخفضة فمسافة التوقف قصيرة.



لقد ظهر المنطق العائم ونظرية المجموعات العائمة في سيتينيات القرن الماضي إلا أن استخدامه استغرق حوالي عشرين سنة . وله تطبيقات عديدة وهامة في التحكم والطب. وهذه التقنية تحسن القوة الحسابية ونمذجة المعرفة وخاصة من عدة خبراء.

المجموعات العائمة

في نظرية المجموعات التقليدية **crisp set** إذا أخذنا مجموعة X وأخذنا عنصرا ما x فإن لدينا إحدى حالتين إما $x \in X$ أو $x \notin X$. ولكن، لننظر في المثال التالي:

قال الفيلسوف اليوناني "جميع اليونانيين كذابون"، فهل هو صادق؟ في المنطق التقليدي هذه العبارة فيها تناقض أما في المنطق العائم فإن الفيلسوف صادق وكاذب بأن. فالحدود بين الصدق والكذب عائمة.

المجموعة العائمة هي مجموعة ذات حدود عائمة، نعرف لها تابع مميز

$$\mu_A(x) : X \rightarrow [0,1]$$

$$\mu_A(x) = 1 \text{ if } x \text{ is totally in } A;$$

$$\mu_A(x) = 0 \text{ if } x \text{ is not in } A$$

$$0 < \mu_A(x) < 1 \text{ if } x \text{ is partly in } A$$

مثال:

نقول عن رجل أنه قصير تماما إذا كان طوله أقل من 160 cm ، أما إذا كان طوله بين 160 cm و 170 cm فيتناقص انتماءه إلى فئة الرجال القصار من 1 إلى 0.

نقول عن رجل أنه طويل تماما إذا كان طوله أكثر من 190 cm ، أما إذا كان طوله بين 180 cm و 190 cm فيزداد انتماءه إلى فئة الرجال الطوال من 0 إلى 1.

الطول المتوسط تماما هو 175 cm ، ويتناقص الانتماء إلى فئة متوسطي الطول يسارا حتى يصل إلى 165 cm ويمينا حتى يصل إلى 185 cm.

وتكون القواعد عائمة أيضا، لننظر في الأمثلة التالية:

➤ إذا كانت مدة المشروع طويلة، وفريق العمل كبيرا والتمويل غير مناسب فالمخاطرة عالية.

➤ إذا كانت الخدمة ممتازة والطعام لذيذا فإن الإكرامية جيدة.

وهناك طرق لاستنتاج معارف جديدة (عائمة) بتطبيق مثل هذه القواعد.

لمزيد من المعلومات انظر كتاب Negnevsky.

6. مراجع البحث

➤ محاضرات في نظم قواعد المعرفة: كلية المعلوماتية س4 ذكاء صناعي. د. أميمة الدكاك و د. ندى غنيم

➤ كتاب **artificial Intelligence: a guide to intelligent systems** للكاتب **Michael Negnevisky** الطبعة الثانية للناسر **Addison Wisley** عام 2002.

الفصل السادس: التعلم

1. مقدمة

من الأمور التي تميز الكائنات البشرية هي إمكان التعلم. فالطفل يتعلم اللغة من الوسط الذي يعيش فيه، والعامِل يتعلم ممن هو أقدم منه أو من دورات تعليمية وغيرها الشيء الكثير. فهل يمكن أن نزود الآلة بإمكان التعلم؟

استراتيجيات التعلم

التعلم في الذكاء الصناعي:

هو تحصيل المعرفة الصريحة. أي إمكان تحصيل المعرفة وإعادة صياغتها لتصبح صريحة. ويمكن أن نعرف التعلم بأنه تحصيل نموذج للعالم حولنا.

تطور مفهوم التعلم تاريخياً وفق المسار التالي:

بدأنا بفكرة أن من يتعلم يجب أن تكون لديه معرفة. في الصناعة يمكن أن نعلم ربوطاً كيف يدهن آلة ماء، نمسكه باليد وندهن فيتعلم ويدهن وحده (يمكن رسم ذلك)، يتطلب هذا التعلم ذاكرة فقط.

ثم ظهر التعلم بواسطة إرشادات المعلم (المعلم بشر أو برنامج): حين يجد المعلم خطأ يوقف النظام ويصحح الخطأ، بصياغة قواعد على القواعد **meta rules**.

ثم ظهرت الشبكات العصبونية، وهي برمجيات تكرارية فيها متحولات هامة، في كل دورة نقيس درجة النجاح ونغير في هذه المتحولات لتحسين النجاح.

ثم ظهرت في السيتينيّات نظم تتعلم المفاهيم (نعلم النظام أمثلة عن المفهوم وأمثلة معاكسة له، مفهوم الطاولة: نعطيه صور لطاولات وصور لأشياء أخرى ليست طاوولات). الأمثلة تفيد التعميم والأمثلة المعاكسة تفيد التخصيص إلى أن نصل إلى وصف أصغري للمفاهيم. ثم ظهر التجميع المفاهيمي في صفوف تنطلق من العام إلى الخاص.

التعلم بواسطة التفسير يعتمد على قواعد الاستدلال الاستنتاجية والاستنباطية. لدينا مثال واحد، ومعرفة حول المجال المدروس، نستخدمها باستمرار لبناء تفسير يبين ملائمة المثال للمفهوم المراد تعلمه ولاشتقاق توصيف عام للمفهوم انطلاقاً من تعميم التفسير.

ثم ظهر التعلم بالقياس أو بالمماثلة، فيتعرف النظام المتشابهات بين المفهوم الذي يود تعلمه ومفهوم معروف ليحدد الميزات التي تبقى من المفهوم المعروف والميزات المضافة. أصبح بإمكان النظام معرفة ما يجب تعلمه.

لدى بناء أي نظام تعلم، يجب تحقيق الخطوات التالية:

➤ كشف الحاجة إلى التعلم. مثال الحاجة إلى بناء برنامج يلعب الشطرنج.

➤ تحصيل المعلومات واختيار المفيد منها. نعطي النظام قواعد اللعب ونتركه يلعب، حين يخسر نعود إلى الخطوات التي سببت الخسارة.

➤ تحويل المعلومات إلى معرفة. صياغة قواعد على القواعد لتحسين الأداء.

➤ مكاملة المعارف واستخدامها في النظام. النظام أصبح جاهزا للعب بنفسه.

نظرا لأهمية النظم المبنية على القواعد، والجهود البشرية الكبيرة المطلوبة لاستنباط واستخراج قواعد جيدة من الخبراء، من الطبيعي أن نتساءل عن إمكان تعلم قواعد النظم الخبيرة آليا.

يوجد نوعان أساسيان من طرق التعلم:

➤ التعلم الاستقرائي **Inductive**

➤ والتعلم الاستدلالي (الاستنتاجي) **Deductive**.

ويمكن استخدام كلا الأسلوبين في تعلم القواعد.

2. التعلم الاستقرائي: الشبكات العصبونية

هي إحدى الطرائق التي تمكن الآلات من أن تتعلم، وذلك بالتعرض لمجموعة عينات مؤلفة من مُدخلات مقرونة بالخرج الملائم لكل مُدخل. ومع أن هناك العديد من البنى الحسابية المختلفة التي يمكن استخدامها، فإننا نركز هنا على الشبكات ذات الأوزان القابلة للتعديل. يتحقق التعلم بتكرار تعديل الأوزان في الشبكة إلى أن يصبح الأداء "حساب الفعل" مقبولا. وأنت تسمية الشبكات العصبونية **neural networks** لأنها تتمزج بعض خواص العصبونات الحية.

نتأمل الآن مسألة التعلم التالية:

لدينا مجموعة Ξ من متجهات X أبعادها n ومكوناتها x_i حيث $i=1, \dots, n$. يمكن لهذه المتجهات أن تكون متجهات السمات (يمكن أن تكون ترددات صوت في إشارة صوتية، أو قيم تحويل فورييه لها) التي يحسبها مكون المعالجة الإدراكية في الوكيل التفاعلي. وكما ذكرنا آنفاً، يمكن أن تكون قيم المكونات أعدادا حقيقية أو قيما بوليانية. ونعلم أيضا الفعل الملائم (معرفة الصوت من تردداته) a ، لكل X في Ξ . يمكن أن تكون هذه الأفعال هي التي يرى المتعلم أن المدرس يقوم بها استجابة لمجموعة من المدخلات. تسمى هذه الأفعال المقرونة أحيانا لصيقات **labels** المتجهات أو صفوف **classes** المتجهات. تُولف المجموعة Ξ إضافة إلى اللصاقات المقرونة بها ما يعرف بمجموعة التدريب **training set**. تكمن مشكلة تدريب الآلة في إيجاد دالة $f(X)$ تستجيب لعناصر مجموعة التدريب "على وجه مقبول". ونهدف عادة إلى أن يتطابق الفعل الذي تحسبه الدالة f مع لصيقة أكبر قدر ممكن من المتجهات في Ξ . ونظرا لكون اللصاقات تعطى مع متجهات المُدخل نقول إن إجرائية التدريب مراقبة **supervised**.

ولكن، حتى لو وجدنا دالة تستجيب على نحو ملائم لمجموعة التدريب، فعلى أي أساس يركز اعتقادنا بأنها ستستجيب على نحو ملائم للمدخلات التي لم ترها خلال التدريب؟

إضافة إلى الدلائل التجريبية التي تدعم الاعتقاد بذلك، هناك مجموعة من النظريات التي تبين (بشروط معينة) أنه إذا كانت مجموعة التدريب "تموجاً" لأنماط المدخلات الأخرى التي يحتمل مصادفتها، أي أنها تمثل تمثيلاً جيداً كل فضاء المدخلات، فإن هذه المدخلات الأخرى تولد "على الأرجح" مخرجات "صحيحة تقريباً". في الواقع، هناك طرائق عديدة لتقدير الدرجة المحتملة لضبط **accuracy** دالة **f** جرى تعلمها، عند تطبيقها على مدخلات مشابهة (لكن غير مرئية حتى الآن).

إن دراسة الشبكات العصبونية وتطبيقاتها تخرج عن نطاق هذا المقرر ولكن يمكن إعطاء أمثلة بسيطة تبين عملها.

لنفترض أن لدينا عدة صور متساوية البعد كتب على كل منها رقم ما، بخط اليد. الشبكة العصبونية هي نظام يأخذ دخلاً مجموعة سمات للصور (قد تكون بكسلات الرقم، وقد تكون تحويلات خاصة تحسب من الصورة)، وخرجه هو قرار يبين الرقم المدخل.


في مرحلة التدريب نمرر الصور الواحدة تلو الأخرى، ونعطي النظام الخرج الموافق الذي نرجوه لهذا النظام. كأن نقول عن كل صورة الرقم الموافق لها. ننفذ خوارزمية الشبكات العصبونية بحيث نغير أوزان الربط بين عقد الدخل (السمات) وعقد الخرج بحيث إذا أعيد إدخال الأمثلة تعطي المخرجات الموافقة. نقول إنه قد جرى تدريب الشبكة العصبونية بطريقة **supervised** (مع معلم لأنه يجب وجود شخص يحدد الخرج المناسب لكل دخل في مرحلة التدريب).

بعد ذلك، إذا أدخلنا صورة غير الصور التي دربنا النظام عليها، فسيكشف النظام (الشبكة العصبونية) المخرج الأقرب إليها. نقول إن الشبكة قد تعلمت الأرقام، وتستطيع تعرف أرقام من صور لم ترها من قبل.


في الحقيقة، تكمن إحدى الطرق بأخذ قياسات من المداخل وأخذ توزيعين لها ثم جمع النواتج وبحسب عتبة إما أن يهيج العصبون فيكون خرجه موجوداً أو لا فلا يطابق الخرج الموافق.

يبين الشكل التالي كيف نحاول نمذجة عمل العصبونات الحيوية بعصبونات صناعية حسابية:


The biological neuron



The model of a neuron



أما حل مسألة تصنيف بسيطة بخرج وحيد فيمكن أن تتم بعصبون له خرج وحيد يبينه الشكل التالي:



بهذه الفكرة، ترى هل بإمكاننا تعلم قواعد جديدة مفيدة في النظم الخبيرة؟ فيكون النظام قد اكتسب خبرة جديدة ومعرفة جديدة؟

نعتبر التعلم باستخدام الشبكات العصبونية من النوع الاستقرائي وذلك لأن الوظائف التي يجري تعلمها

هي تخمينات (فرضيات) حول

بعض الوظائف الهامة غير

المعروفة. وفي تعلم ناجح،

تعطي التخمينات، نموذجا،

مُخرجات صحيحة لمعظم

المُدخلات الممكنة، ولكنها يُمكن

أيضا أن تخطئ. تقوم طرائق

التعلم الاستقرائي بإيجاد قواعد

OK	يجب الموافقة على القرض
COLLAT	ضمانة القرض الإضافية مقبولة
PYMT	طالب المال (العميل) قادر على سداد دفعات القرض
REP	للعامل سمعة مالية جيدة
APP	تخمين الضمانة أكبر من مبلغ القرض بقدر كافٍ
RATING	للعامل دفعات دورية منتظمة
INC	دخل العميل يتجاوز مصاريفه
BAL	للعامل نشرة موازنة ممتازة

جديدة في مجال ما، لا يمكن اشتقاقها من أي قواعد سابقة. ويمكن أن ندرس بعض الطرق لتعلم القواعد استقرائيا في حساب الفرضيات والحساب الإسنادي.

3. التعلم الاستنتاجي عبر الأمثلة

يحسن تعلم القواعد الاستنتاجي فعالية أداء النظام، وذلك باستنتاج قواعد جديدة من حقائق المجال وقواعده المعروفة سابقا. يُمكن أيضا اشتقاق النتائج التي يتوصل إليها النظام مستخدما هذه القواعد الإضافية، وذلك من دون هذه القواعد. ولكن بوجود هذه القواعد، يكون أداء النظام أشد فاعلية. سنشرح فيما يلي تقنية لاستنتاج القواعد الإضافية تسمى تقنية التعميم المبني على الشرح

Explanation-Based Generalization (EBG)

ولتأطير مناقشتنا، سنستخدم المثال البسيط لقبول القروض المصرفية. وهو كما يلي:

يُمكن أن نتصور، مثلا، موظف المصرف المسؤول عن منح القروض، وهو يستخدم نظاما كهذا

يُساعدُه لِيُقرَّر: أَمِنَ المُناسِبَ مَنَحَ قَرْضٍ شَخْصِيٍّ لِأَحَدِ المُتَعَامِلِينَ؟ قَدْ يَأْخُذُ نِظَامُ القُرُوضِ العَمَلِيَّ، فِي الحِسَابِ، الكَثِيرَ مِنَ العَوَامِلِ، أَكْثَرَ بِكَثِيرٍ مِمَّا يَمْكَنُ أَنْ نَأْخُذَهُ فِي المِثَالِ التَّوْضِيحِيِّ التَّالِي. وَلَكِنْ، يَمْكَنُنَا إعْطَاءَ فِكْرَةٍ تَقْرِيبِيَّةٍ عَنِ كَيْفِيَّةِ عَمَلِ مِثْلِ هَذَا النِّظَامِ بِتَوْصِيفِ إِصْدَارِ مَبْسُطٍ جَدَا. لِنَفْتَرِضَ أَنَّنا نَقْصِدُ أَنْ تُشِيرَ الذَّرَاتُ فِي الدُّوَلِ إِلَى الفَرَضِيَّاتِ المُرَافَقَةِ لَهَا:

وَعَلَى هَذَا يُمْكَنُ اسْتِخْدَامُ القَوَاعِدِ التَّالِيَةِ بِغِيَّةِ اتِّخَاذِ القَرَارِ:

1. $\text{COLLAT} \wedge \text{PYMT} \wedge \text{REP} \supset \text{OK}$
2. $\text{APP} \supset \text{COLLAT}$
3. $\text{RATING} \supset \text{REP}$
4. $\text{INC} \supset \text{PYMT}$
5. $\text{BAL} \wedge \text{REP} \supset \text{OK}$

لِنَفْتَرِضَ الآنَ أَنَّ مَوْظِفَ القُرُوضِ فِي البَنْكِ يَريدُ أَنْ يَعْرِفَ النَتِيجَةَ لِعَمَلٍ مُعَيَّنٍ: أَهِيَ OK أَمْ لَا؟. لِإثْبَاتِ OK ، يَجِبُ عَلَى مُحَرِّكِ الاسْتَدْلَالِ أَنْ يَبْحِثَ عَنِ بَرْهَانٍ فِي شَجَرَةِ AND/OR مُسْتَخْدِمًا السَّلْسَلَةَ الأَمَامِيَّةَ أَوِ الخَلْفِيَّةَ (أَوْ كِلَيْهِمَا). سَيَكُونُ لِهَذِهِ الشَّجَرَةِ (إِنْ وُجِدَتْ) عَقْدَةٌ OK بِاعْتِبَارِهَا عَقْدَةُ الجَذْرِ، وَحَقَائِقُ (يَحْدُدُ المُسْتَخْدَمُ أَنَّهَا صَحِيحَةٌ أَوْ هِيَ مُوجُودَةٌ فِي قَاعِدَةِ بَيَانَاتِ حَقَائِقِ النِّظَامِ) بِاعْتِبَارِهَا عَقْدَةُ الأَوْرَاقِ. يَرْتَبِطُ الجَذْرُ بِالأَوْرَاقِ (عَادَةً، بِوَاسِطَةِ عَقْدٍ وَسِيطَةٍ) بِاسْتِخْدَامِ القَوَاعِدِ.

بِاسْتِخْدَامِ القَوَاعِدِ السَّابِقَةِ بِنَمَطِ السَّلْسَلَةِ الخَلْفِيَّةِ، يَمْكَنُ البَرْهَنَةُ عَلَى OK هَدَفَ المُسْتَخْدَمِ إِمَّا بِالْبَرْهَنَةِ عَلَى BAL وَ REP مَعًا both ، أَوْ بِالْبَرْهَنَةِ عَلَى each كُلٍّ مِنَ COLLAT وَ PYMT وَ REP . تَمَثَّلُ هَاتَانِ الطَّرِيقَتَانِ البَدِيلَتَانِ لِلْبَرْهَنَةِ عَلَى OK بِالْعَقْدَتَيْنِ OK الوَاقِعَتَيْنِ تَحْتَ الجَذْرِ تَمَامًا. نَذْكُرُ أَنَّنا نَسْمِي هَذِهِ العَقْدَ بِعَقْدِ OR ، فِي شَجَرَةِ AND/OR . يُمْكَنُ البَرْهَنَةُ عَلَى عَقْدَةٍ خَلْفَهَا عَقْدُ OR فِي شَجَرَةِ AND/OR ، بِالْبَرْهَنَةِ عَلَى أَحَدِ هَؤُلَاءِ الخَلْفِ. وَبِتَطْبِيقِ القَوَاعِدِ الأُخْرَى، كَمَا هُوَ مُبَيَّنٌ، تَنْتَجُ مَجْمُوعَاتُ أُخْرَى مِنَ العَقْدِ عَلَيْنَا أَنْ نَبْرهنَ عَلَيْهَا.

لِنَفْتَرِضَ أَنَّهُ عَوَضًا عَنِ أَنْ تَكُونَ لَدَيْنَا قَوَاعِدُ لِهَذِهِ المَسْأَلَةِ، سَتَكُونُ لَدَيْنَا مَجْمُوعَةٌ تَدْرِيبٌ تَتَكُونُ مِنْ قِيَمِ الوَاصِفَاتِ لَعَدَدٍ كَبِيرٍ مِنَ الأَشْخَاصِ (العَمَلَاءِ). وَلِتَوْضِيحِ ذَلِكَ، لِنَتَأَمَّلِ المَعْطِيَّاتِ المَعْطَاةَ فِي الجَدُولِ.

يَمْكَنُ الحَصُولُ عَلَى هَذَا الجَدُولِ، مِثْلًا، بِالرَّجُوعِ إِلَى سَجَلَاتِ طُلُوبَاتِ القُرُوضِ المَصْرُفِيَّةِ وَالقَرَارَاتِ الَّتِي اتَّخَذَهَا مَوْظِفُو المَصْرَفِ بِشَأْنِ قَبُولِ هَذِهِ القُرُوضِ.

نَسْمِي عَنَاصِرَ مَجْمُوعَةِ التَّدْرِيبِ الَّتِي تَأْخُذُ فِيهَا OK القِيَمَةَ True بِالْعَيِّنَاتِ المُوجِبَةِ $\text{positive instances}$ ، وَالعَنَاصِرَ الَّتِي تَأْخُذُ فِيهَا القِيَمَةَ False بِالْعَيِّنَاتِ السَّالِبَةِ $\text{negative instances}$. وَنَريدُ، بِاسْتِخْدَامِ مَجْمُوعَةِ التَّعَلُّمِ السَّابِقَةِ، اسْتِنتَاجَ قَوَاعِدٍ مِنَ الشَّكْلِ:

$$\alpha_1 \wedge \alpha_2 \wedge \dots \wedge \alpha_n \supset OK$$

حيث α_i ذرات فرضية من المجموعة {APP, RATING, INC, BAL}.

إذا كان لمقدمة (الشروط القبلية) القاعدة القيمة True من أجل عينة معينة في مجموعة التعلم، قلنا إن القاعدة تشمل cover هذه العينة. يُمكننا تغيير أي قاعدة لنجعلها تشمل عددا أقل من العينات وذلك بإضافة ذرة إلى مقدمتها. مثل هذا التغيير يجعل القاعدة أكثر خصوصية specific. يُمكن لقاعدتين أن تشملنا عددا من العينات أكبر مما تشمله قاعدة واحدة. ثم إن إضافة قاعدة، تجعل النظام الذي يستخدم هذه القواعد أكثر عمومية more general. ننشئ مجموعة القواعد التي تشمل كل العينات الموجبة، دون غيرها، في مجموعة التعلم.

يُمكن أن تكون عملية البحث عن مثل هذه القواعد مكلفة حسابيا. سنشرح هنا طريقة "جشعة greedy" نسميها "فرق تسد Separate and Conquer". نحاول في هذه الطريقة، أولا، إيجاد قاعدة واحدة تشمل العينات الموجبة فقط - حتى لو كانت لا تشمل جميع العينات الموجبة. نبحت عن مثل هذه القاعدة بالبدا بقاعدة تغطي جميع العينات (الموجبة والسالبة)، ثم نجعلها بالتدريج أكثر خصوصية بإضافة ذرات لمقدمتها. ولأن قاعدة واحدة قد لا تكفي لشمول جميع

العمل	APP	RATING	INC	BAL	OK
1	1	0	0	1	0
2	0	0	1	0	0
3	1	1	0	1	1
4	0	1	1	1	1
5	0	1	1	0	0
6	1	1	1	0	1
7	1	1	1	1	1
8	1	0	1	0	0
9	1	1	0	0	0

معطيات المصرف

(نستخدم 1 لـ True و 0 لـ False)

العينات الموجبة، نضيف القواعد بالتدريج (بجعلها خصوصية بالقدر الذي نحتاج إليه) حتى الوصول إلى مجموعة كاملة من القواعد التي تشمل كل العينات الموجبة دون غيرها.

لنر تطبيق هذه الطريقة على مثالنا. نبدأ أولا بالقاعدة المؤقتة التالية، التي تشمل جميع العينات: $T \supset OK$

يجب أن نضيف الآن ذرة لنجعلها تشمل عددا أقل من العينات السالبة، بالعمل باتجاه شمول العينات الموجبة فقط.

والسؤال المطروح هنا هو:

أي من الذرات التالية {APP, RATING, INC, BAL} يجب إضافتها؟

يوجد العديد من المعايير الممكن استخدامها للاختيار. وللإبقاء على مناقشتنا بسيطة سنجعل قرارنا

يعتمد على النسبة، السهلة الحساب، التالية: $r_\alpha = n_\alpha^+ / n_\alpha$

حيث n_α هي العدد الكلي للعينات (الموجبة والسالبة) التي تشملها المقدمة (الجديدة) للقاعدة بعد إضافة الذرة α إلى هذه المقدمة. أما n_α^+ فهو العدد الكلي للعينات الموجبة التي تشملها المقدمة (الجديدة) للقاعدة بعد إضافة الذرة α إلى هذه المقدمة.

سنختار الذرة α التي تعطي أكبر قيمة لـ r_α .

تكون قيم النسب r_α في مثالنا هي:

$$\begin{aligned} r_{APP} &= 3/6 = 0.5 \\ r_{RATING} &= 4/6 = 0.667 \\ r_{INC} &= 3/6 = 0.5 \\ r_{BAL} &= 3/4 = 0.75 \end{aligned}$$

ولذلك، سنختار الذرة **BAL**. مما يُعطي القاعدة المؤقتة: **BAL \supset OK**

تشمل هذه القاعدة العينات الموجبة 3 و 4 و 7. إلا أنها تشمل العينة السالبة 1، ولذلك يجب أن نخصصها أكثر.

سنستخدم التقنية نفسها لاختيار ذرة أخرى. وبالطبع، فإن حساب r_α الآن يجب أن يأخذ بالاعتبار أننا قررنا أن المكون الأول في مقدمة القاعدة هو **BAL**. لذا يكون لدينا:

$$r_{APP} = 2/3 = 0.667 \quad r_{RATING} = 3/3 = 1.0 \quad r_{INC} = 2/2 = 1.0$$

لدينا هنا تعادل بين **RATING** و **INC**. سنختار **RATING** لأنها تعتمد على عينة أكبر. (استكشف نتائج اختيار الذرة **INC** عوضاً عنها).

تشمل القاعدة الجديدة **BAL \wedge RATING \supset OK** العينات الموجبة فقط، ولذلك، فلسنا بحاجة إلى إضافة ذرات جديدة إلى مقدمة هذه القاعدة. إلا أن هذه القاعدة لا تشمل جميع العينات الموجبة، ولا تشمل تحديد العينة الموجبة 6. ولذلك علينا إضافة قاعدة أخرى.

لتعلم القاعدة التالية، نقوم أولاً بحذف جميع العينات الموجبة المشمولة بالقاعدة الأولى من الجدول

للحصول على المعطيات المختصرة المبينة في الجدول

الجديد. ونعيد الآن تطبيق الإجراءات ثنائية بكمالها مع

الجدول المختصر، بدءاً من القاعدة **T \supset OK** التي تشمل

بعض العينات السالبة 1 و 2 و 5 و 8 و 9. و لاختيار

الذرة الواجب إضافتها إلى مقدمة القاعدة نحسب:

$$\begin{aligned} r_{APP} &= 1/4 = 0.25 \\ r_{RATING} &= 1/3 = 0.33 \\ r_{INC} &= 1/4 = 0.25 \\ r_{BAL} &= 0/1 = 0.0 \end{aligned}$$

العميل	APP	RATING	INC	BAL	OK
1	1	0	0	1	0
2	0	0	1	0	0
3	1	1	0	1	1
4	0	1	1	1	1
5	0	1	1	0	0
6	1	1	1	0	1
7	1	1	1	1	1
8	1	0	1	0	0
9	1	1	0	0	0

معطيات المصرف

(نستخدم 1 لـ True و 0 لـ False)

نجد أن r_{RATING} هي الأكبر، وهذا يعطي القاعدة $RATING \supset OK$.

تشمل القاعدة $RATING \supset OK$ العينات السالبة 5 و 9، ولذا يجب إضافة ذرة جديدة إلى مقدمتها .
نحسب إذن النسب:

ونختار $RATING$ وهذا يُعطي القاعدة:

$APP \wedge RATING \supset OK$

تشمل هذه القاعدة العينة السالبة 9. ويجعل هذه القاعدة أكثر خصوصية (باتباع الطريقة نفسها) تنتج
أخيرا القاعدة التالية:

$$r_{RATING} = 1/2 = 0.5$$

$$r_{INC} = 1/2 = 0.5$$

$$r_{BAL} = 0/0$$

$APP \wedge RATING \wedge INC \supset OK$

تشمل القاعدتان المستنتجتان وهما:

$BAL \wedge RATNG \supset OK$

$APP \wedge RATING \wedge INC \supset OK$

العميل	APP	RATING	INC	BAL	OK
1	1	0	0	1	0
2	0	0	1	0	0
5	0	1	1	0	0
6	1	1	1	0	1
8	1	0	1	0	0
9	1	1	0	0	0

المعطيات المختصرة

جميع العينات الموجبة دون غيرها. وبهذا نكون قد
انتهينا.

ولأن إجرائية إيجاد القواعد تستخدم بحثا جشعا
(شرها)، يجب ألا يفاجئنا إمكان اختصار (تبسيط)
قواعد التعلم أحيانا.

(نستخدم 1 لـ True و 0 لـ False)

يمكننا أن نختبر في حالة كل قاعدة، لنرى:

أ بالإمكان حذف القاعدة دون تغيير القرارات

المتخذة من قبل القواعد المتبقية بشأن مجموعة عينات التدريب؟ فإذا لم نجد أي تأثير (أو إذا
وجد تأثير ضعيف على الدقة عندما يكون ثمة ضجيج في المعطيات) أمكن حذف القاعدة.

وبالمشابهة، يمكننا أن نختبر في حالة كل ذرة في قاعدة لنرى:

أبالإمكان حذف هذه الذرة وبتأثير أضعف؟

في الواقع، إذا كانت المعطيات كثيرة الضجيج، فقد نحتاج إلى تغيير المعيار الذي يقضي بأن تشمل
القواعد المكتسبة (التي جرى تعلمها) جميع العينات الموجبة دون غيرها.

وعوضا عن ذلك، قد نسمح لكل قاعدة أن تشمل "في الدرجة الأولى" العينات الموجبة سامحين (كما
يجب أن نفعل في حالة المعطيات الكثيرة الضجيج) بأن تشمل كل قاعدة عددا قليلا من العينات السالبة.
وبالمشابهة، يُمكن أن نسمح لمجموعة القواعد المكتسبة أن تخفق في شمول بعض العينات الموجبة .
تسمح عمليات "التشذيب" هذه، مع التعديلات التي تتحمل الضجيج (المتسامحة مع الضجيج) بالتخفيف
من خطر التلبيق الزائد **Overfitting**.

يمكننا باختصار عرض إجرائية تعلم القواعد هذه، بالرماز المفترض **pseudocode**. ونسمي هذه

الخوارزمية بخوارزمية فرق تسد العامة (GSCA).
وفي هذه الخوارزمية:

Ξ مجموعة عينات التدريب الابتدائية، لسمات بقيم اثنائية، لكل منها لصيقة بقيمة الذرة γ .
 π مجموعة القواعد المطلوب تعلمها.

ρ إحدى القواعد، نتيجتها γ ومقدمتها (شرطها) Γ (عطف ذرات).

α ذرة مشتقة من إحدى السمات في Ξ .

الرماز المفترض pseudocode لخوارزمية فرق تسد العامة GSCA:

1. استبدئ $\Xi_{cur} \leftarrow \Xi$
 2. استبدئ مجموعة قواعد خالية $\phi \leftarrow \pi$
 3. كرر repeat. تضيف الحلقة الخارجية قواعد، حتى تشمل π جميع (أو معظم) العينات موجبة.
 4. استبدئ $\Gamma \leftarrow T$
 5. استبدئ $\rho \leftarrow \Gamma \supset \gamma$
 6. كرر repeat. تضيف الحلقة الداخلية ذرات إلى Γ ، حتى تشمل ρ فقط (أو في الدرجة الأولى) عينات موجبة.
 7. اختر ذرة α choose(α) تضيفها إلى Γ . (هذا الخيار غير حتمي، وقد يُستخدم للتعقب الرجوعي).
 8. $\Gamma \leftarrow \Gamma \wedge \alpha$
 9. حتى until تغطي ρ العينات الموجبة فقط (أو في الدرجة الأولى في Ξ_{cur}).
 10. $\pi \leftarrow \pi, \rho$ (نضيف القاعدة ρ إلى مجموعة القواعد π).
 11. (العينات الموجبة في Ξ_{cur} والمشمولة بـ π) $\Xi_{cur} \leftarrow \Xi_{cur} - \pi$
 12. حتى until تشمل π جميع (أو معظم) العينات الموجبة في Ξ .
- يمكن استخدام حساب الإسناديات عوضاً عن الفرضيات لتعلم قواعد جديدة، فيكون مثلاً إذا تحققت إسنادية لعدد كبير من الأمثلة نقوم بالتعميم ونقول أن الإسنادية صحيحة مهما يكن المثال (استخدام المكمي العمومي).

4. الألعاب

يمكن استخدام التعلم في الألعاب لتعلم قواعد اللعب. ويدخل هذا النوع من التعلم ضمن طرائق التعلم بوجود معلم ويعتمد على الحصول على المعرفة المفيدة عبر إرشادات المعلم. يتكون نظام التعلم في هذه الحالة من المراحل التالية:

1. انتقاء التلميذ (برنامج التعلم) للعناصر التي تسمح ببناء هيكل مفهومي أولي يمثل مختلف المفاهيم النموذجية والاستدلالات المفيدة للوصول إلى السياق الخاص بالتعلم.
2. تمثيل العناصر المكتسبة إلى تمثيل داخلي في النظام بهدف التحليل أو غير ذلك.
3. تصفية موجهة للهيكل المفهومي الأولي وذلك بتحليل حالات عدم الترابط أو الإبهام أو النقصان المكتشفة فيه.

في أدبيات الذكاء الصناعي برمجة لعبة البوكر، وهي لعبة ذات معلومات ناقصة تعتمد على الحظ والحالة النفسية للاعب وهي بذلك تختلف عن لعبة الشطرنج ذات المعلومات الواضحة (الرقعة تبين تماما حالة اللاعب وخصمه). وقد برمجها **Waterman** في عام 1970.

تتألف لعبة البوكر من خمس مراحل:

1. التوزيع: لكل لاعب خمس أوراق ويضع قطعة في إناء (لا يعرف كل لاعب سوى ورقه).
 2. الرهان: بالتناوب على كل لاعب أن يتخذ أحد ثلاث قرارات:
 - الرهان: يضع مبلغا يساوي على الأقل آخر رهان للخصم،
 - الاستنكاف: ينهي سلسلة الرهان،
 - الانسحاب: ينتهي اللعب ويأخذ الخصم ما في الإناء دون أن يكشف عن أوراقه.
 3. التبديل: يبدل كل لاعب 0 إلى 3 أوراق ويعلم الخصم عن عددها.
 4. الرهان: كالسابق.
 5. كشف الورق: من لديه نقاط أكثر بحسب الأوراق التي معه يربح ما في الإناء.
- تعتبر عملية الخداع أساسية لأنها محاولة للربح بأوراق سيئة وذلك بإدهاش الخصم إلى أن ينسحب. برمجة لعبة البوكر هي وضع قواعد لاتخاذ القرار بناء على تحليل الوضع وإقرار الفعل. مبدأ التعلم كما يلي:

- تعرض حالة لعب، يبين المعلم القرار المناسب اتخاذه والأسباب التي دعت لاتخاذ القرار.
- في حال توصل النظام الخبير إلى قرار مغاير (حسب مجموعة القواعد بداخله)، يجري تغييره سواء بإضافة قواعد جديدة أو تغيير قواعد سابقة لجعله يتوافق مع المعطيات التي أدلى بها المعلم.
- بعد عدة دورات مشابهة من التعلم يتقارب النظام الخبير إلى شكل يأخذ قرار المعلم نفسه في غالب الأحيان. تكمن الصعوبة في:
 - تقييم القرار المتخذ وفي حال كان سيئا معرفة القاعدة المسؤولة عنه.
 - تغيير القواعد الموجودة: وهنا نبحث عن قاعدة قابلة للتغيير (لها نفس جزء الشرط لقاعدة

التدريب) واقعة قبل القاعدة الخاطئة (التي قادت إلى القرار الخاطئ) تماماً فنغيرها بحسب المطلوب وإلا نبحث عن قاعدة قابلة للتغيير بعد القاعدة الخاطئة تماماً فنغيرها وإلا نضيف قاعدة التدريب قبل القاعدة الخاطئة.

بهذا نكون قد أعطينا فكرة عن التعلم في الذكاء الصناعي واستخدامه في الألعاب.

5. مراجع البحث

- محاضرات في التعلم من مدرسة ESIMAG في غرونوبل 1992.
- نوبة "الذكاء الصناعي 2: التعلم الآلي" إعداد د. بسام الكردي. المعهد العالي للعلوم التطبيقية والتكنولوجيا 1995.
- كتاب **artificial Intelligence: a guide to intelligent systems** للكاتب Michael Negnevsky الطبعة الثانية للنشر Addison Wisley عام 2002.

الفصل السابع: التواصل والإدراك والفعل


1. مقدمة

رأينا في فصول سابقة كيف نبحث في فضاء الحالات عن حل لمسألة معينة. في هذا الفصل، سنفترض أن وكيلًا (ربوطًا) يستطيع القيام بعدد من الأفعال الأولية مثل النقاط غرض وتحريكه من مكان إلى آخر في بيئة تتضمن أغراض أخرى.

2. حلقة التحسس/التخطيط/الفعل

تعتمد فعالية طرائق التخطيط، المعتمدة على البحث، على عدة فرضيات متينة. غالبًا ما تكون هذه الفرضيات غير محققة للأسباب التالية:

1. يمكن للإجرائيات المرئية ألا تعطي دوماً المعلومات الضرورية الخاصة بحالة البيئة (لأنها تحوي ضجيجاً أو لا تتأثر بالخواص الهامة).
2. يمكن للأفعال ألا تحوي دوماً تأثيراتها المنمذجة (لأن النماذج غير دقيقة بقدر كاف أو لأن نظام التأثير ينتج أحياناً أخطاء عند تنفيذ الأفعال).
3. يمكن وجود إجرائيات فيزيائية أخرى في العالم أو وكلاء آخر، ويمكن لهذه الإجرائيات أن تغير العالم بحيث تتداخل مع أفعال الوكلاء.
4. مشكلة أخرى يسببها وجود التأثيرات الخارجية: يمكن للعالم أن يتغير خلال الزمن الذي يستغرقه بناء المخطط، بحيث لا يبقى المخطط مناسباً.
5. يمكن أن يطلب من الوكيل أن يقوم بفعل، قبل إتمام البحث عن حالة الهدف.
6. حتى لو كان لدى الوكيل الوقت الكافي، قد لا يسمح له مورده من ذاكرة الحساب متابعة البحث إلى حالة الهدف.



يوجد أسلوبان رئيسيان للتعامل مع مثل هذه الصعوبات للمحافظة على المميزات الأساسية للتخطيط المعتمد على البحث.

- الأول: باستعمال طرائق الاحتمالات لصياغة الارتيايات الإدراكية، والبيئية، وارتيايات المؤثرات.
- والآخر: نحاول العمل في محيط الصعوبات بإضافة عدة فرضيات وتقريبات مختلفة.

عوضاً عن أن نلاحق هنا الطرائق المعتمدة على الاحتمالات، نقترح بنية، تسمى بنية تحسس/تخطيط/فعل، بحيث تتجاوز بعض التعقيدات المنتشرة بكثرة في العديد من

التطبيقات. إن العقلاني في هذه البنية هو أنه حتى لو أنتجت الأفعال أحيانا تأثيرات غير متوقعة وحتى لو لم يستطع الوكيل أحيانا أن يقرر في أي حالة من العوالم هو، يمكن التعامل مع هذه الصعوبات تعاملًا ملائمًا بجعل الوكيل يحصل على تغذية راجعة مستمرة من بيئته أثناء تنفيذ مخططة.

إحدى الطرائق لضمان التغذية الراجعة المستمرة هي التخطيط لسلسلة من الأفعال، ثم تنفيذ أول فعل فقط من هذه السلسلة، ثم تحسس حالة البيئة الناتجة، ثم إعادة حساب عقدة البداية، ثم تكرار الإجرائية. يقال عن الوكلاء التي تختار الأفعال بهذه الطريقة إنها وكلاء تحسس/تخطيط/فعل. على كل حال، ولكي تصبح هذه الطريقة فعالة، يجب ألا يتجاوز زمن حساب المخطط الزمن المخصص لكل فعل (انظر الشكل). في البيئات المعتدلة (تلك التي تتساهل ببعض الأخطاء)، "يحسب معدل" الأخطاء في التحسس والفعل على سلسلة حلقات تحسس/تخطيط/فعل.

تسمح التغذية الراجعة البيئية في حلقة تحسس/تخطيط/فعل في حل بعض الارتباكات الإدراكية والبيئية، وارتباكات المؤثرات. ومع ذلك، لكي تصبح هذه التغذية الراجعة فعالة، يجب أن نفترض أن التحسس والفعل هما -وسطيا- دقيقين. هذه الفرضية محققة في الكثير من التطبيقات. يمكن للوكيل غالبا أن يحسن دقة الإدراك وذلك بمقارنة المعطيات المتحسنة المباشرة بالنموذج المحفوظ للحالة الظاهرة.

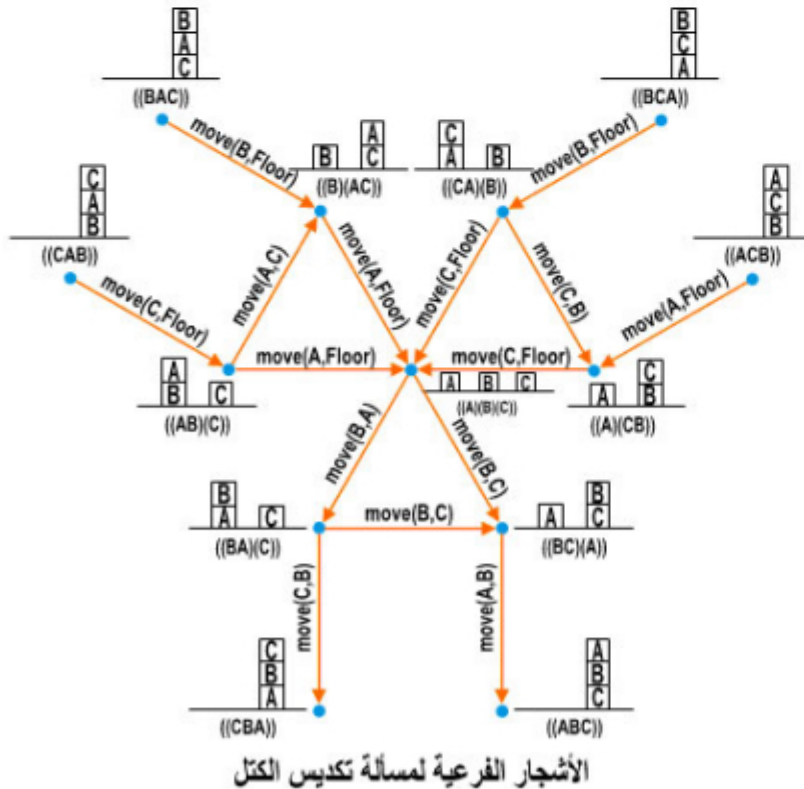
تكمّن إحدى الطرائق، لتقليل الشك ولتعويض النقص في معرفة الوكيل لتأثيرات أفعاله، في إجراء

تغذية راجعة من البيئة باستمرار، ويمكن أيضا استخراج معلومات مفيدة من تجربة البحث ومن تجربة الأفعال في العالم. سوف نناقش الطرائق المختلفة التي يمكن فيها للوكيل أن يتعلم كيف يخطط ويعمل بفعالية أشد.

3. تعلم دوال تجريبية

إذا كان الوكيل لا يملك دالة تجريبية جيدة لكي يستطيع تقدير التكلفة إلى الهدف، يمكنه في بعض الأحيان تعلم مثل هذه الدالة.

سوف نشرح أولا إجراء تعلم سهلا جدا يلائم الحالة التي يمكن فيها حفظ قائمة شاملة لجميع العقد الممكنة.



نفترض أولا أن لدى الوكيل نموذجا جيدا لتأثيرات أفعاله، وأنه يعلم أيضا تكاليف الانتقال من أي عقدة إلى عقد خلفها.

نبين في الشكل الأفعال الممكنة من الحالة الابتدائية (BCA) وكيفية الوصول إلى الحالة الهدف (CBA) في مسألة الكتل.

نستهل إجرائية التعلم بإعطاء القيمة 0 للدالة \hat{h} قيمة ابتدائية لجميع العقد، ثم نبدأ خوارزمية بحث A^* . بعد توسيع العقدة n_i لتوليد الخلف $S(n_i)$ ، نعدل $\hat{h}(n_i)$ كما يلي:

$$\hat{h}(n_i) \leftarrow \min_{n_j \in S(n_i)} [\hat{h}(n_j) + c(n_i, n_j)]$$

حيث $c(n_i, n_j)$ هي تكلفة التحرك من n_i إلى n_j .

يمكن حفظ قيم \hat{h} في جدول من العقد (لأنه لا يوجد منها سوى عدد قليل نسبيا). نفترض أيضا أنه إذا تم توليد عقدة هدف، ولتكن، n_g ، فنعلم أن $\hat{h}(n_g) = 0$. ومع أن إجرائية التعلم هذه لا تساعدنا على الوصول إلى الهدف في المرة الأولى التي نبحث فيها، بأسرع من البحث ذي التكلفة الموحدة، فإن البحث المتتالي إلى الهدف ذاته (انطلاقا من حالات البداية المختلفة المحتملة) سوف يتسارع باستعمال الدالة \hat{h} المتعلمة. وبعد عدة عمليات بحث، تنتشر تدريجيا، بالعودة إلى الوراء انطلاقا من عقد الهدف تقديرات أفضل فأفضل للدالة الحقيقية h .

أما إذا لم يكن لدى الوكيل نموذج جيد لتأثيرات أفعاله، فيمكنه تعلمها وتعلم دالة \hat{h} في الوقت ذاته أيضا بإجرائية مشابهة، ولو أنه يجب تنفيذ عملية التعلم في العالم الواقعي عوضا عن نموذج فضاء الحالات. (بالطبع، يمكن لمثل هذا التعلم أن ينطوي على المصادفة!) نفترض أن الوكيل يملك بعض الوسائل لتمييز الحالات التي يزورها فعلا وأنه يمكنه تسميتها وبناء بيان شامل أو جدول لتمثيل الحالات مع قيمها المقدرة، والانتقالات الناتجة عن الأفعال. ونفترض أيضا أنه إذا لم يعلم الوكيل تكاليف أفعاله، فإنه يتعلمها بعد تنفيذها.

تبدأ الإجرائية بعقدة واحدة فقط، تمثل الحالة التي يبدأ منها الوكيل. ثم ينفذ فعلا، يمكن أن يكون عشوائيا، فينتقل إلى حالة أخرى. وكلما زار حالة، سماها وأرفق معها قيمة لـ \hat{h} كما يلي:

$$\hat{h}(n_i) \leftarrow [\hat{h}(n_j) + c(n_i, n_j)]$$

حيث n_i هي العقدة التي نفذ عندها الفعل a مثلا، و n_j هي العقدة الناتجة، و $c(n_i, n_j)$ هي تكلفة الفعل المكتشفة، و $\hat{h}(n_j)$ تقدير لقيمة n_j ، والتي تساوي 0 إذا كانت n_j لم تزر سابقا قط وإلا تحفظ في الجدول. كلما كان الوكيل على وشك تنفيذ فعل عند العقدة n ، التي حفظت عقد خلفها في البيان، اختار فعلا حسب السياسة التالية:

$$a = \underset{a}{\operatorname{argmin}} [\hat{h}(\sigma(n, a)) + c(n_i, \sigma(n, a))]$$

حيث $\sigma(n, a)$ هي وصف للحالة التي وصلنا إليها من العقدة n بعد تنفيذ الفعل a .

يبدأ إجراء التعلم الخاص هذا بالسير عشوائياً، مع احتمال العثور على هدف، وتنتشر قيم لـ \hat{h} أفضل بالعودة إلى الوراء من جراء المحاولات المتتالية، مؤدية إلى مسارات أفضل. ليس من الضرورة تقويم جميع خلف العقدة n حين تحديث $\hat{h}(n)$ ، وذلك لأن الفعل المختار عند العقدة n هو الذي يقودنا إلى عقدة مقدرة تقع على المسار ذي التكلفة الصغرى من n إلى الهدف. لأننا نبني النموذج تدريجياً، من الممكن دمج "التعلم في العالم" في "التعلم والتخطيط في النموذج".

يمكن، مع ذلك، أن تنتج التقانة مسارات تعلم غير أمثلية لأنه من الجائز للعقد على المسارات الأمثلية ألا تكون قد زيرت قط. إن السماح بالأفعال العشوائية من حين لآخر (عوضاً عن تلك المختارة من قبل السياسة المتعلمة) يساعد الوكيل على تعلم مسارات جديدة (يمكن أن تكون أفضل) إلى الأهداف. يعتبر تنفيذ أفعال عشوائية إحدى الطرائق لتعامل الوكيل مع ما يسمى "الموازنة بين استكشاف (مسارات جديدة) واستعمال (المسارات المعروفة المتعلمة سابقاً)". من الجائز أيضاً وجود طرائق أخرى للتحقق أن جميع العقد قد زيرت.

في بعض الأحيان، يكون بناء بيان شامل أو إنشاء جدول في جميع العقد مع الانتقالات فيما بينها غير عملي. عندما يكون لدينا نموذج لتأثيرات الأفعال (أي: عندما يكون لدينا مؤثرات تحول وصف حالة إلى وصف حالة خلف)، فإنه يمكننا تطبيق إجراءات بحث مقدرة باستخدام دالة تقويم. نموذجياً، يمكن للدالة أن تعطي التقويم ذاته لعقد متعددة، لذا من الممكن تطبيق الدالة على وصف الحالة، على حين ليس الأمر كذلك بالضرورة فيما يخص حفظ جميع العقد وقيمها بشكل كامل في جدول.

نخمن أولاً مجموعة من الدوال الجزئية التي نعتقد أنها يمكن أن تكون عناصر جيدة للدالة التجريبية. على سبيل المثال، في أحجية الثمانية يمكننا استعمال الدوال التالية:

$W(n)$ = عدد المربعات التي هي في غير موضعها

$P(n)$ = مجموع المسافات التي يبعد بها كل مربع عن "مكانه"

وأي دوال أخرى يمكن أن تتعلق بمقدار قرب الموضع من الهدف. ثم نكتب الدالة التجريبية باعتبارها تركيباً خطياً موزوناً.

نكتب الدوال التجريبية للدوال المتعلقة بمقدار قرب الموضع من الهدف باعتبارها تركيباً خطياً موزوناً كما يلي:

$$\hat{h}(n) = w_1 W(n) + w_2 P(n) + \dots$$

يمكن أن نضبط \hat{h} عند كل توسيع لعقدة. فبعد توسيع العقدة n_i لإنتاج عقد الخلف $S(n_i)$ ، نضبط الأوزان

بحيث:

$$\hat{h}(n_i) \leftarrow \hat{h}(n_i) + \beta \left(\min_{n_j \in S(n_i)} [\hat{h}(n_i, n_j) + c(n_i, n_j)] - \hat{h}(n_i) \right)$$

أو، بإعادة ترتيب العلاقة كما يلي:

$$\hat{h}(n_i) \leftarrow (1 - \beta)\hat{h}(n_i) + \beta \min_{n_j \in S(n_i)} [\hat{h}(n_i, n_j) + c(n_i, n_j)]$$

حيث $0 < \beta \leq 1$ هو متوسط معدل التعلم الذي يتحكم في مدى قرب $\hat{h}(n_i)$ من $\min_{n_j \in S(n_i)} [\hat{h}(n_i, n_j) + c(n_i, n_j)]$. عندما تكون $\beta = 0$ ، لا يجري أي تغيير البتة؛ وعندما تكون $\beta = 1$ ، نجعل $\hat{h}(n_i)$ تساوي $\min_{n_j \in S(n_i)} [\hat{h}(n_i, n_j) + c(n_i, n_j)]$. تؤدي قيم β الصغيرة إلى التعلم الشديد البطء، على حين يمكن لـ β بالقرب من 1 أن تجعل التعلم خاطئا وغير متقارب.

نلاحظ أنه يمكن أيضا تطبيق تقانة التعلم هذه حتى في الحالات التي لا يوجد فيها نماذج لتأثيرات الأفعال. هذا يعني، أنه يمكن تطبيق التعلم في العالم الواقعي كما شرحنا سابقا. نقوم بتنفيذ خطوة (يمكن أن تكون عشوائية أو مختارة حسب سياسة الفعل الناشئة)، ونقوم دالتيها \hat{h} قبل تنفيذها وبعده، ثم ملاحظة تكلفة الخطوة، وأخيرا إجراء تعديلات الأوزان.

4. الجوائز عوضا عن الأهداف

عند دراسة استراتيجيات البحث في فضاء الحالة، افترضنا أن للوكيل مهمة وحيدة قصيرة الأجل يمكن وصفها باستخدام شرط الهدف. وكان الهدف تغيير العالم إلى أن يحقق نموذج (على شكل بنية معطيات) شرطا محددا.

في العديد من المسائل ذات الطابع العملي، لا يمكن صياغة المهمة بسهولة. عوضا عن ذلك، يمكن للمهمة أن تكون متغيرة باستمرار. يعبر المستخدم عن رضاه أو عدم رضاه عن أداء المهمة بإعطاء الوكيل جوائز **Rewards** إيجابية أو سلبية من حين لآخر. تصبح مهمة الوكيل الإكثار من كمية الجوائز التي يحصل عليها.


يمكن تحويل الحالة الخاصة التي هي مهمة بلوغ الهدف البسيطة في إطار العمل هذا بمكافأة الوكيل إيجابيا (مرة واحدة فقط) عندما يبلغ الهدف، وسلبيا (بمقدار تكلفة الفعل) في كل مرة ينفذ فعلا. في هذا النوع من بيئة المهمات، نبحث عن توصيف لسياسة الفعل بحيث تكثر من الجوائز. وتكمن إحدى مشكلات الاستمرار في مهام غير منتهية، في الجوائز المستقبلية التي يمكن أن تكون لانهائية، وبذلك يصعب اتخاذ قرار بكيفية جعلها أكبر ما يمكن. إحدى الطرائق لمعالجة هذا، هي في تقليص الجوائز المستقبلية بعامل ما. بمعنى آخر، يفضل الوكيل الجوائز التي تتوفر في القريب العاجل على تلك التي تؤجل إلى المستقبل البعيد.

5. التخطيط في الألعاب ذات اللاعبين

تعد مسألة التخطيط والعمل ضمن بيئة مأهولة بأكثر من لاعب فعال من التحديات. يمكننا الذهاب قليلا إلى أبعد من استعمال بنية تحسس/تخطيط/فعل: التي لا تخطط في العمق ضمن مستقبل مجهول بسبب نقص في معرفة كيفية تصرف المجموعة الالعبة الأخرى. ومع ذلك، يمكن للاعب - عندما تتوفر المعرفة- بناء خطط تأخذ بالحسبان صراحة آثار أفعال مجموعة لاعبة أخرى. لتأمل الحالة الخاصة للاعبين اثنين فقط. نجد في الوضع المثالي عندما يأخذ كل لاعب بالحسبان تصرف الآخر، أن دور كل لاعب يتخلله دور اللاعب الآخر بالتناوب (يتناوب اللاعبان اللعب). فيلعب اللاعب الأول، ثم الآخر، وهكذا دواليك.

ليكن، على سبيل المثال، في عالم شبكة الفضاء المبين في الشكل التالي ربوطان **Robots**:

يسمى الأول "أسود" والثاني "أبيض" يمكن أن يتحرك كل منهما إلى الخلية المجاورة في الصف أو العمود ذاته. هذان اللاعبان يلعبان بالتناوب (لنقل إن الأبيض سيبدأ)، ومن يجيء دوره، عليه أن يتحرك إلى أي مكان. لنفترض أن هدف اللاعب الأبيض أن يكون مع اللاعب الأسود في خلية واحدة، فيصبح هدف اللاعب الأسود أن يمنع ذلك من الحصول. يمكن للاعب الأبيض أن يخطط بناء شجرة بحث، نجد فيها أيضا -مع تناوب المستويات- كل حركات اللاعب الأسود المحتملة. يبين الشكل نفسه جزءا من شجرة البحث هذه.



وبهدف اختيار الحركة الأولى الفضلى، يحتاج اللاعب الأبيض إلى أن يحلل الشجرة كي يحدد أفضل النتائج، أخذا بالحسبان أن اللاعب الأسود سيلعب ليمنع اللاعب الأبيض من أن يصل إلى هدفه. وفي بعض حالات التضارب الخاصة بهذه الطريقة، من المحتمل أن يجد أحد اللاعبين حركة لا يهمله ما

يلعب الآخر بعدها، وبذلك يصل هذا اللاعب إلى هدفه. والأشيع، بسبب محدودية الحساب والزمن، لا يستطيع أي من اللاعبين أن يجد حركة تضمن له الربح. سوف نعرض طرائق البحث المحدودة العمق التي تفيد في إيجاد الحركات المعقولة تجريبيا في هذه الحالات. وفي جميع الأحوال، وبعد أن يختار الحركة الأولى، يقوم بها، ثم يراقب (يدرك) ما يفعله اللاعب الآخر، ثم يعيد إجرائية التخطيط على نمط تحسس/تخطيط/فعل.

إن المثال المختار: "عالم الشبكة" هو مثل على ما نسميه "ألعاب ذات لاعبين، كاملة المعلومات، ناتج الجمع صفر". لدينا في أحد الإصدارات، لاعبان، يلعبان بالتناوب كل بدوره إلى أن يربح أحدهما (ومن ثم يخسر الآخر)، أو تكون النتيجة تعادلا. لدى كل لاعب نموذج تام وكامل لبيئة اللعب ولجميع حركاته وحركات الخصم الممكنة وأثرها. (مع أنه لا يملك أي لاعب المعرفة التامة لما يمكن فعلا أن يلعبه الآخر بكل الحالات). تعطينا دراسة الألعاب من هذا النوع نظرة ثاقبة إلى بعض جوانب مسائل التخطيط التي هي أعم والتي تشمل عدة لاعبين، حتى لو لم يكن هنالك تضارب بين أهداف اللاعبين.

إن كثيرا من الألعاب الشائعة، ومنها لعبة الشطرنج، ولعبة الداما، ولعبة غو Go، تنتمي إلى هذا النوع من الألعاب. في الواقع، صممت برامج حاسوبية لتلعب مثل هذه الألعاب في مستويات عالية من المهارة في بعض الحالات. ومع ذلك فإن لعبة تيك تاك تو Tic-Tac-Toe ليست حاسوبيا باللعبة المثيرة، ولكنها تفيد ببساطتها في توضيح تقانات البحث. وهناك من الألعاب (مثل النرد، لعبة الطاولة) ما ينطوي على عنصر الحظ، مما يجعلها أكثر تعقيدا في تحليلها.

6. إجراء min-Max

نسمي اللاعبين من الآن فصاعدا MAX و MIN. وستكون مهمتنا إيجاد "أفضل" حركة للاعب MAX. لنفترض أن اللاعب MAX سيلعب أولا، ثم يلعب اللاعبان بالتناوب. وهكذا، تقابل مستويات العمق ذات الترتيب الزوجي المواقع التي يكون فيها على اللاعب MAX أن يلعب (دور MAX)؛ نسمي هذه العقد عقد MAX. وتقابل مستويات العمق ذات الترتيب الفردي المواقع التي يكون فيها على اللاعب MIN أن يلعب (دور MIN)؛ وهذه العقد هي عقد MIN. (علما أن العقدة العليا في شجرة الألعاب لها العمق صفر). وتحوي الطبقة ذات "عمق الطبقة k" في شجرة الألعاب العقد ذات العمق 2k و 2k+1. يحدّد التوسع في البحث في أشجار الألعاب عادة باستخدام مصطلح عمق الطبقة: يقاس مقدار التقدم إلى الأمام بعدد أزواج الحركات المتناوبة للاعبين MAX و MIN.

كما أسلفنا سابقا، إن البحث الكامل (إلى الربح، أو الخسارة، أو التعادل) لبيانات معظم الألعاب هو أمر مستحيل حاسوبيا. فقد قدر بيان لعبة الشطرنج الكامل بنحو 1040 عقدة. وهذا يستغرق نحو 1022 قرنا لتوليد بيان البحث الكامل للعبة الشطرنج، حتى لو افترضنا أن توليد عقدة الابن تحتاج لـ 1/3 نانوثانية.

(مع العلم أن الكون قدر عمره بنحو 108 قرنا). أضف إلى ذلك أن تقانات البحث التجريبية لا تخفض عامل التفريع الفعلي بقدر كاف لكي يساعد كثيرا. لذلك، في حالة بعض الألعاب المعقدة علينا قبول أن البحث حتى النهاية هو أمر مستحيل (اللهم إلا عند الوصول إلى نهاية اللعبة). عوضا عن ذلك، علينا استعمال طرائق مشابهة لآلية البحث المحدودة الأفق المشروحة أعلاه.

يمكن أن نستعمل إما طريقة عرضا أولا، أو عمقا أولا، وإما الطرائق التجريبية *heuristic*، على أن نغير الآن شروط الانتهاء. يمكن أن نخصص عدة شروط انتهاء صناعية معتمدة على عوامل مثل حدود زمن البحث، أو حدود حجم التخزين، أو عمق أعماق عقدة في شجرة البحث. ومن المألوف أيضا في لعبة الشطرنج، على سبيل المثال، ألا ننهي اللعبة إذا كانت إحدى عقد الأوراق تمثل موقعا "مثيرا للنقاش"، فيستبدل به موقع ذو فائدة مباشرة.

بعد انتهاء البحث، علينا استنتاج تقدير لأفضل أول حركة من شجرة البحث. يمكن حساب هذا التقدير بتطبيق دالة تقويم سكونية على عقد الأوراق في شجرة الألعاب. تقيس دالة التقويم "قيمة" موقع عقدة ورقة. يعتمد هذا القياس على بعض خصائص مختلفة يتصور أنها تؤثر في هذه القيمة؛ فعلى سبيل المثال، في لعبة الشطرنج، تقيس بعض الخصائص المفيدة ميزة الحجر النسبية، والتحكم في الوسط، والتحكم في الوسط من قبل الملك، وهلم جرا.

من المعتاد عند دراسة أشجار الألعاب أن نعتد الاصطلاح الآتي:

- مواقع اللعب التي هي في مصلحة اللاعب **MAX** تؤدي إلى قيمة موجبة لدالة التقويم،
- على حين تؤدي المواقع التي هي في مصلحة اللاعب **MIN** إلى قيمة سالبة لدالة التقويم؛
- وأخيرا تقابل القيم القريبة من الصفر مواقع اللعب التي ليس من الواضح أنها في مصلحة أي من اللاعبين **MAX** أو **MIN**.

يستخلص الإجراء المسمى إجراء **minimax** أفضل أول حركة. (بغية التسهيل، نشرح هذا الإجراء وغيره من الإجراءات المتفرعة منه كما لو كان بيان اللعبة شجرة ألعاب حقيقية). نفترض أن اللاعب **MAX** يفضل العقدة ذات أكبر تقويم، عندما يكون عليه أن يختار بين عقد الأوراق في شجرة البحث. ونظرا لإمكان اختياره هذه العقدة بالفعل حين يأتي دوره باللعب، فإن القيمة المرجعة لعقدة **MAX** الأب لعقد الأوراق **MIN** تساوي القيمة العظمى للقيم السكونية لهذه العقد. من جهة أخرى، إذا كان على اللاعب **MIN** أن يختار بين عقد الأوراق، فإنه من المسلم به أن يختار تلك العقدة التي لها أصغر تقويم (يعني الأكثر سلبا). ونظرا لإمكان اختياره هذه العقدة حين يأتي دوره باللعب، فإننا نعطي العقدة **MIN** الأب لعقد الأوراق **MAX** القيمة المرجعة التي تساوي القيمة الصغرى للقيم السكونية لهذه العقد. وعند الانتهاء من إعطاء جميع الأبناء لكل عقد الأوراق القيم المرجعة، نرجع قيم مستوى آخر، باعتبار أن **MAX** سيختار عقدة **MIN** التالية التي لها أعظم قيمة مرجعة، على حين سيختار **MIN** عقدة الخلف

MAX التي لها أصغر قيمة مرجعة.

نستمر بارجاع القيم، مستوى تلو الآخر بدءاً من الأوراق، إلى أن، في النهاية، تعطى القيم المرجعة إلى خلف عقدة البداية. لقد افترضنا أن اللاعب **MAX** هو الذي يبدأ باللعب، لذا عليه أن يختار حركته الأولى تلك العقدة الخلف التي تقابل أعظم قيمة مرجعة.

يوضح مثال بسيط طريقة "مينيماكس" وهو لعبة نيك تاك تو.

يتناوب في لعبة نيك تاك تو اللاعبان وضع علامة في جدول مصفوفة 3×3 . العلامة الأولى هي إشارة الضرب (\times)، والثانية هي الدائرة (O). ويربح الذي يحصل أولاً على صف كامل، أو عمود، أو قطر مملوء بعلامته.

لنفترض أن إشارة الضرب (\times) هي علامة اللاعب **MAX**، والدائرة (O) للاعب **MIN**، وأن على اللاعب **MAX** أن يبدأ أولاً باللعب. نستعمل طريقة البحث عرضاً أولاً إلى أن نولد جميع عقد المستوى الثاني، ثم نطبق على مواقع هذه العقد دالة التقويم السكونية، وذلك إذا كان حد العمق هو 2.

لتكن دالة التقويم $e(p)$ للموقع p الذي نحصل عليه ببساطة كما يلي:

⚡ إذا لم يكن الموقع p موقعاً رابحاً لأي من اللاعبين، فإن:

$$e(p) = (\text{عدد الصفوف والأعمدة والأقطار الكاملة التي بقيت مفتوحة للاعب MAX}) - (\text{عدد الصفوف والأعمدة والأقطار الكاملة التي بقيت مفتوحة للاعب MIN})$$

⚡ إذا كانت p موقعاً رابحاً للاعب **MAX**، فإن: $e(p) = \infty$ (نستعمل ∞ هنا للدلالة على عدد موجب كبير جداً)

⚡ أما إذا كانت p موقعاً رابحاً للاعب **MIN**، فإن: $e(p) = -\infty$

وهكذا إذا كانت p كما في الشكل الجانبي، يكون لدينا: $e(p) = 6 - 4 = 2$.


المفتوح لـ **MAX** القطران والعمودان الطرفيان وأسفل سطرين.



ما بقي مفتوحاً لـ **MIN** هو العمودان الطرفيان والسطران الطرفيان.




ونستفيد من التناظر في توليد مواقع الخلف؛ لذا، جميع الحالات في اللعبة التالية تعد متطابقة:



وفي بداية اللعبة، يبقى عامل تفريع شجرة نيك تاك تو صغيرا بفضل التناظر؛ وفي نهايتها، يبقى صغيرا أيضا بفضل قلة عدد الخانات الفارغة المتبقية.

نبين في أشكال تالية الشجرة المولدة بالبحث إلى العمق 2. حيث نجد على يمين عقد الأوراق التقويم السكوني، والقيم المرجعة لباقي العقد محاطة بدائرة. ولأن أكبر لـ $\frac{1}{2}$ قيمة مرجعة، فسيجري اختيارها حركة أولى. وتتوافق هذه الحركة، على سبيل المصادفة، مع أفضل أول حركة للاعب MAX في حال إجراء بحث تام.




المرحلة الأولى من البحث في لعبة نيك تاك تو

لنفترض الآن، مثبعين حلقة تحسس/تخطيط/فعل، أن اللاعب MAX قد لعب الحركة $\frac{1}{2}$ ورد اللاعب MIN بوضع دائرة في الخلية فوق إشارة الضرب تماما، وهي حركة سيئة للاعب MIN، الذي يظهر أنه لم يستعمل إستراتيجية بحث جيدة. يعطي البحث التالي للاعب MAX إلى العمق 2 أسفل التشكيلة الناتجة شجرة البحث المبينة في الشكل، إذ توجد الآن "أفضل" حركتين ممكنتين.

ولنفترض أن اللاعب MAX قد لعب تلك المشار إليها في الشكل. ويلعب الآن اللاعب MIN اللعبة التي

تجنبه الخسارة الحتمية، مما ينتج:



يتابع اللاعب **MAX** البحث، ليحصل على الشجرة المبينة، التي تشكل بعض عقد الأوراق فيه عقدا رابحة للاعب **MIN** ولهذا تقوم بـ $-\infty$. وعندما تحسب القيم المرجعة، نرى أن أفضل حركة للاعب **MAX** هي أيضا الحركة الوحيدة التي تجنبه الخسارة المباشرة. الآن يمكن للاعب **MIN** أن يدرك أن اللاعب **MAX** سيربح في حركته التالية، لذا يستسلم اللاعب **MIN** بلباقة.

يمكن أن يكون هذا البحث طويلا جدا لذلك يمكن تصغيره بوضع شروط على الحركات وهذا يقود إلى إجرائية تدعى ألفا-بيتا. يمكن دراستها في مرجع الذكاء الصناعي باللغة العربية.

الفصل الثامن: استشراف المستقبل: الخوارزميات المتطورة

1. مقدمة

النظم الذكية هي نظم قادرة على حل المشاكل خلال زمن مقبول. على الإنترنت مثلاً يوجد عدد من النظم الذكية:

➤ وكلاء أذكىاء:

- تساعد على تصفح الوب، وإيجاد المعلومات ومطابقة المفردات التي نبحث عنها
- ترشح البريد الإلكتروني
- تنفذ إلى قواعد المعطيات، وتلخص المعلومات
- تقوم بالتقريب عن المعلومات باستخدام محركات بحث ذكية
- تتصفح وثائق ذات حجم هائل
- تراقب المعطيات وتحذر إذا حصلت بعض الأفعال

➤ يوجد أيضاً نظم خبيرة:

- تطابق بين التساؤلات وإجابات على **FAQ Frequently Asked Questions**
- تقوم بتصفح ذكي لقواعد معطيات بنوعيات مختلفة
- تقوم بتصفح وثائق ذات حجم هائل

لقد تعرفنا في فصول سابقة على معظم تقنيات الذكاء الصناعي هذه: النظم الخبيرة، المنطق العائم، الشبكات العصبونية. لم نتعرف على تقنية الخوارزميات الجينية التي تعد حديثة نسبياً؛ فما هي هذه الخوارزميات وكيف تعمل؟

2. الخوارزميات الجينية

تسمى أيضاً بالحساب التطوري. فهل يمكن للتطور أن يكون ذكياً؟ وهل تتصرف الأعضاء الحية تجاه بيئتها بطريقة ذكية؟

يعتمد المنهج التطوري على نماذج حسابية مستقاة من الانتقاء الطبيعي والخوارزميات الجينية.

يتضمن الحساب التطوري: خوارزميات جينية و استراتيجيات تطور و برمجة جينية.

لن نتكلم عن أصل نظريات داروين في البقاء. سنتكلم عن الخوارزميات الجينية التي قدمها **John Holland** في سبعينيات القرن الماضي، وكان هدفه أن يقوم الحاسوب بما تقوم به الطبيعة. أما وصف هذه الخوارزمية فهو كما يلي:

- يتألف الصبغي الصناعي من سلسلة من الجينات يمثل كل منها بالبت 0 أو 1.
- الطبيعة قادرة على التكيف والتعلم وإيجاد الصبغيات (الجينات) الجيدة على نحو أعمى.

◀ لدينا قياس لمدى ملء الصبغى للحفاظ على الإنتاج الذي يأتي نتيجة عمليتين:

- التزاوج: مبادلة جزأين من صبغيين (بداية الأول مع نهاية الثاني وبالعكس) (صورة slide

(20)

- الطفرة: إجراء تغيير في مكان عشوائي من الصبغى. (صورة slide 21)

الخوارزميات الجينية الأساسية:

1. تمثيل نطاق متغيرات المسألة المطلوب حلها بصبغى طوله ثابت. نفترض عدد الصبغيات N واحتمال التزاوج p_c واحتمال الطفرة p_m .
2. تعريف تابع مواءمة يقيس ملء الصبغى للحل.
3. توليد صبغيات عشوائياً عددها N . x_1, x_2, \dots, x_N
4. حساب ملء كل من الصبغيات $f(x_1), \dots, f(x_N)$.
5. اختيار زوج من الصبغيات باحتمال يتعلق بملئها.
6. توليد زوج جديد من الصبغيات بعد تطبيق التزاوج والطفرة.
7. وضع الصبغيات الجديدة في مجموعة جديدة.
8. تكرار الخطوة (5) إلى أن تصبح المجموعة الجديدة بحجم N .
9. الاستعاضة عن مجموعة الآباء بمجموعة الأبناء.
10. العودة إلى الخطوة (4) والتكرار إلى أن يتحقق شرط توقف (منها إيجاد الحل).

مثال

لنفترض أننا نود إيجاد عدد بين 0 و 255 يكون عدد واحداته يساوي عدد أصفاره.

1. كل صبغى هو بايت بثمانى بتات مثلاً العدد $h=126$ يمثل بـ 01111110. حجم مجموعة الصبغيات $N=4$.

$$h = \begin{bmatrix} 0 & 1 & 1 & 1 & 1 & 1 & 1 & 0 \end{bmatrix} = 126$$

2. نعرف تابع الملاءمة $f(h) = 8 - |n_1 - n_0|$ القيمة الصغرى له هي 0 حين n_1 أو n_0 يساوي 8، والقيمة العظمى 8 حين $n_1 = n_0 = 4$.

3. توليد 4 أعداد عشوائياً ولتكن: h_1, h_2, h_3, h_4 وتمثيلها هو:

0	1	1	1	1	1	1	0
0	0	0	0	0	0	0	1
1	1	1	1	1	1	1	0
0	0	1	0	0	1	0	0


4. حساب توابع الملاءمة للصبغيات الأربعة $f(h_i)$ وهي: 4, 2, 4, 2.

h_1	0	1	1	1	1	1	1	0	$f(h_1) = 8 - 6 - 2 = 4$
h_2	1	1	1	1	1	1	1	0	$f(h_2) = 8 - 7 - 1 = 2$
h_3	0	0	1	0	0	1	0	0	$f(h_3) = 8 - 2 - 6 = 4$
h_4	0	0	0	0	0	0	0	1	$f(h_4) = 8 - 1 - 7 = 2$


5. اختيار صبغيين بحسب احتمالاتها وملاءمتها $p(h_i) = \frac{f(h_i)}{\sum_{j=1}^N f(h_j)}$ فيكون:

$$p(h_1) = p(h_3) = 4/12; p(h_2) = p(h_4) = 2/12$$

نقسم المجال $[0, 1]$ إلى N جزء مقسمة بحسب $p(h_i)$ ، ثم نختار قيمة عشوائية $r \in [0, 1]$ ونأخذ الصبغي الموافق (يمكن اختيار صبغي عشوائياً من بين الأربعة وكأنها على طرف دولاب)، ثم نختار صبغياً آخر.



6. إجراء المزاوجة والطفرة (نفترض أن الزوجين h_1, h_2 و h_1, h_3 وأن المزاوجة تتم في موضع البت $c = 3$ للزوج الأول، وفي الموضع $c = 6$ للزوج الثاني، على سبيل المثال.



7. على الصبغيات الأطفال الأربعة نختار طفرة (تغيير بعض البتات)، ثم ندرس توابع المواءمة الجديدة فنحصل على القيم: 6, 8, 4, 6. وهنا لا حاجة للتكرار لأن أحد الصبغيات ملائم ويحقق القيمة 8.

0	1	1	0	0	1	0	0	$f = 8 - 3 - 5 = 6$
0	0	1	1	0	1	1	0	$f = 8 - 4 - 4 = 8$
0	0	1	0	0	1	1	0	$f = 8 - 3 - 7 = 4$
1	0	1	1	1	1	0	0	$f = 8 - 5 - 3 = 6$

كل تكرار للخوارزمية يسمى جيلاً، ويتراوح عدد الأجيال نموذجياً لمسألة بسيطة بين 50 و

500.

قد يبقى أداء الأجيال مستقراً لفترة طويلة.
إذا لم نحصل على نتائج مرضية بعد عدد من الأجيال فإننا نعيد الخوارزمية من بدايتها.

3. البرمجة الجينية

البرمجة الجينية هي توسعة للخوارزميات الجينية تسعى لتطوير رماز برمجي يحل مسألة معينة (وليس مجموعة بنات).

يجري البحث في فضاء البرامج الحاسوبية الممكنة لحل مسألة ما.

كل برنامج هو سلسلة عمليات تطبق على معاملات.

المشكلة:


إيجاد لغة تقوم بإجراء تزاوج وطفرات على التتابع وعلى المعطيات. هذه اللغة يجب أن تسمح بمعاملة البرنامج على أنه معطيات وبتنفيذ المعطيات الجديدة على أنها برامج.

LISP هي اللغة المختارة لهذا الغرض، وهي لغة برمجة للقوائم نعتبر كل تابع هو قائمة رأسها التابع وجسمها محدداته.

مثال:

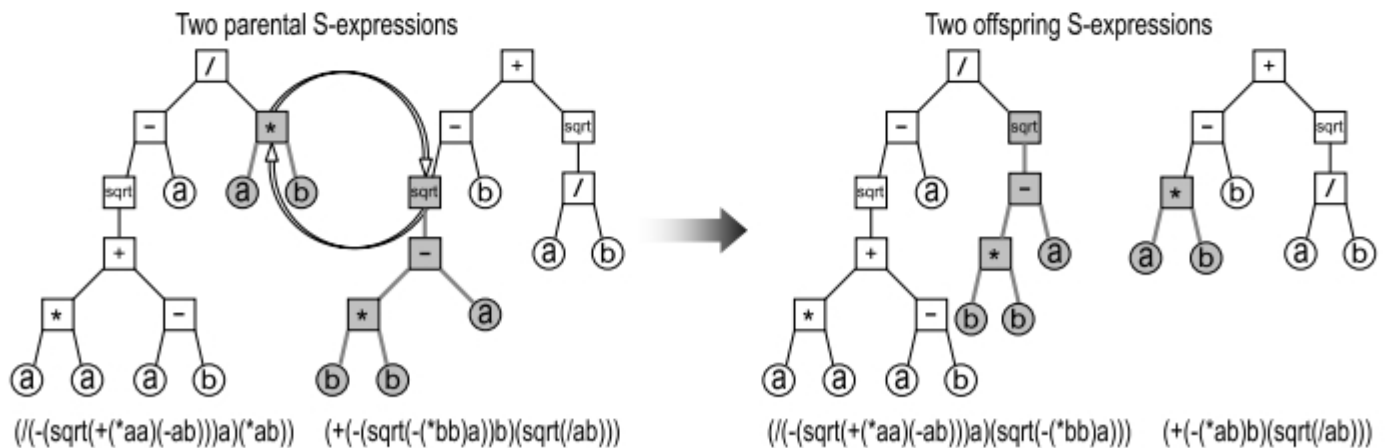
(5 3 +) هي قائمة **list** رأسها **+** وجسمها **3** و **5**، وقد يكون أي عنصر فيها هو أيضاً قائمة.

LISP S-expression (- (* A B) C)



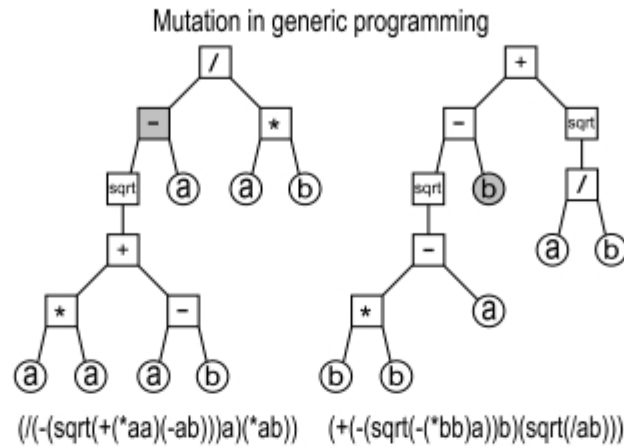
يبين الشكل إلى اليسار التعبير **AB-C** الذي يكتب بالشكل: **(- (* A B) C)**

وهنا عوضاً عن أن يكون الأبوان سلسلتي بنات سيكونان شجرتين مثل الشكل السابق، التزاوج بينهما هو تبديل بين فرعين من فروع كل شجرة كما في الشكل التالي:



في الشكل السابق، الصورة إلى اليسار تبين الأبوين، وإلى اليمين الطفلين الناتجين من التزاوج.

أما الطفرات فتظهر في العقد الرمادية من الشكل التالي:



4. نظم ذكية هجينة

رأينا أن المشاكل التي يتطلب حلها ذكاء صناعي هي على عدة أنواع:

- **التشخيص:** الاستدلال على سوء عمل غرض ما من سلوكه، وإيجاد حلول.
 - **الاختيار:** اختيار أفضل خيار من قائمة خيارات.
 - **التنبؤ:** التنبؤ بتصرف غرض في المستقبل من تصرفاته الماضية.
 - **التصنيف:** إسناد غرض إلى صف معين معرف.
 - **العنقدة:** تقسيم مجموعة غير متجانسة من الأغراض إلى مجموعات جزئية متجانسة.
 - **الأمثلة:** تحسين نوعية الحلول حتى الوصول إلى حل أمثل.
 - **التحكم:** التحكم بتصرفات غرض لتحقيق متطلبات معينة بالزمن الحقيقي.
- وفيما يلي سنجري مقارنة بين تقنيات الذكاء الصناعي التي جرت دراستها حتى الآن، استناداً إلى بعض النقاط الهامة.

مقارنة التقنيات الذكية

يمكننا الجدول التالي من المقارنة بين عدة تقنيات للنظم الذكية استناداً إلى بعض النقاط المهمة.

الخوارزميات الجينية	الشبكات العصبونية	النظم العائمة	النظم الخبيرة	النظم المقارنة
تحت الوسط	سيء	جيد	فوق الوسط	تمثيل المعرفة
جيد	جيد	جيد	فوق الوسط	تحمل معرف غير مؤكدة
جيد	جيد	جيد	سيء	تحمل معرف غير دقيقة
جيد	جيد	تحت الوسط	سيء	تكيف
جيد		سيء	سيء	إمكان التعلم

إمكان التوسع	جيد	جيد	سيء	تحت الوسط
كشف المعطيات والتنقيب عنها	سيء	تحت الوسط	جيد	فوق الوسط
الصيانة	سيء	فوق الوسط	جيد	فوق الوسط

والتوجه الحالي هو بناء نظم ذكية هجينة تضم عدداً من التقنيات بأن. قد يكون الهجين أسوأ أو أفضل من النظم غير الهجينة المكونة له، يعتمد ذلك على حسن اختيار كل جزء من النظام الهجين لتحقيق الأفضل.

من هذه النظم:

- نظم تجمع بين النظم العائمة والشبكات العصبونية: **neuro-fuzzy system**.
- نظم تجمع بين النظم الخبيرة والشبكات العصبونية: **neuro-expert system**.
- إن ضم المحاكمة الاحتمالية إلى المنطق العائم والشبكات العصبونية والحساب التطوري يشكل نواة فرع حديث بارز في مجال الذكاء الصناعي يسمى الحوسبة اللينة **soft computing** يهدف إلى بناء نظم قادرة على المحاكمة والتعلم في بيئة غير مؤكدة وغير دقيقة.

(H)
$ \neg H).p(\neg H)$

